

DISERTASI

**SISTEM PAKAR UNTUK PREDIKSI CURAH HUJAN
DENGAN TINJAUAN TEKNIK EKSPLORASI
TERBAIK PADA DERET DATA**

*EXPERT SYSTEM FOR RAINFALL PREDICTION
FINDING BEST EXPLORATION METHOD FOR DATA
SERIES*

INDRASAYU



**PROGRAM PASCASARJANA
UNIVERSITAS HASANUDDIN
MAKASSAR
2013**

SISTEM PAKAR UNTUK PREDIKSI CURAH HUJAN DENGAN TINJAUAN TEKNIK EKSPLORASI TERBAIK PADA DERET DATA

Disertasi
Sebagai Salah Satu Syarat untuk Mencapai Gelar Doktor

Program Studi

Teknik Sipil

Disusun dan diajukan oleh

INDRABAYU

Kepada

**PROGRAM PASCASARJANA
UNIVERSITAS HASANUDDIN
MAKASSAR
2013**

DISERTASI

**SISTEM PAKAR UNTUK PREDIKSI CURAH HUJAN
DENGAN TINJAUAN TEKNIK EKSPLORASI TERBAIK
PADA DERET DATA**

Disusun dan diajukan oleh

INDRABAYU

Nomor Pokok P0800310044

telah dipertahankan di depan Panitia Ujian Disertasi
pada tanggal 21 Juni 2013
dan dinyatakan telah memenuhi syarat

Menyetujui

Komisi Pembimbing,

Prof.Dr.Ir.H. Nadjamuddin Harun, MS

Promotor

Prof.Dr.Ir.H. Muh. Saleh Pallu, M.Eng
Co-promotor

Dr.Ir.H. Andani Achmad, MT
Co-promotor

Ketua Program Studi
Teknik Sipil,

Prof.Dr.Ir.H. Muh. Saleh Pallu, M.Eng

PERNYATAAN KEASLIAN DISERTASI

Yang bertanda tangan di bawah ini:

Nama : INDRABAYU
Nomor mahasiswa : P0800310044
Program studi : Teknik Sipil

Menyatakan dengan sebenarnya bahwa disertasi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri bukan merupakan pengambilalihan tulisan atau pemikiran orang lain. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan disertasi ini hasil karya orang lain, saya bersedia menerima sanksi atas perbuatan tersebut

Makassar, Juni 2013

Yang menyatakan

INDRABAYU



PRAKATA

Bismillahirrahmanirrahim. Puji syukur penulis panjatkan kehadirat Allah SWT yang telah memberikan rahmat dan hidayah serta karunia ilmu-Nya yang tak terbatas sehingga hasil penelitian dengan judul “SISTEM PAKAR UNTUK PREDIKSI CURAH HUJAN DENGAN TINJAUAN TEKNIK EKSPLORASI TERBAIK PADA DERET DATA” ini dapat terselesaikan. Penyelesaian disertasi ini merupakan sebuah proses panjang yang membutuhkan tambahan energi, dan upaya kerja keras dengan manajemen waktu yang tepat.

Sungguh kami sadar bahwa tidak ada hasil yang baik tanpa bantuan dan kerja sama dengan orang lain serta tidak terlepas dari dorongan keluarga dan para sahabat yang tiada henti-hentinya memberikan semangat untuk menyelesaikan studi ini. Terima kasih kepada kedua orang tua kami almarhum H.B. Amirullah dan H.A. ST. Maerani. Istri dan anak tercinta, Sitti Wetenriajeng, Naufal dan Nashwan. Mertua kami yang selalu sabar dan mendukung kami. Serta keluarga besar H.B. Amirullah dan Sidehabi. Disertasi ini lahir dari hasil diskusi dengan para ahli baik dari Perguruan Tinggi, LAPAN, BMKG maupun para praktisi dan pencinta lingkungan. Namun kami sadar bahwa disertasi ini tidak akan mungkin selesai tanpa bimbingan, petunjuk, ridha dan izin Allah SWT. Oleh karena itu melalui Izin-Nya pula ingin saya sampaikan dari hati yang paling dalam rasa terima kasih yang tak terhingga kepada Prof.Dr.Ir.H. Nadjamuddin Harun, MS sebagai promotor yang selama ini memiliki kesibukan luar biasa, namun selalu menyediakan waktunya untuk membimbing kami.

Demikian pula kepada Bapak Prof.Dr.Ir.H. Muh. Saleh Pallu, M.Eng Co-Promotor-1 yang banyak meluangkan waktunya untuk berdiskusi dan memberikan masukan dalam penentuan judul penelitian ini. Hal yang sama ingin saya haturkan pula kepada bapak Dr.Ir.H. Andani Achmad, MT, sebagai Co-Promotor-2 yang telah memberi masukan dan arahan untuk tercapainya tujuan penelitian yang diharapkan.

Terima kasih juga kami sampaikan kepada rektor dan para wakil rektor Universitas Hasanuddin, direktur Pasca Sarjana Unhas, Dekan dan para wakil dekan Fakultas Teknik Unhas, para dosen pasca sarjana dan para staf administrasi pada Pasca Sarjana Fakultas Teknik Unhas yang turut membantu dalam proses perkuliahan hingga proses terlaksananya seminar ini. Tidak lupa kami mengucapkan terima kasih pada teman-teman angkatan S3 Teknik Sipil, utamanya angkatan 2010 dan 2011.

Dan akhirnya kepada semua pihak yang telah memberikan dukungan, baik moral maupun material, serta segala ketulusan dan keikhlasan dengan mengorbankan sebagian waktu, pikiran dan tenaganya, kami hanya dapat berdoa semoga Allah swt dapat membalasnya sebagai bagian dari amal ibadah kepada-Nya, Amin.

Makassar, Juni 2013

Indrabayu

ABSTRAK

INDRABAYU. *Sistem Pakar Untuk Prediksi Curah Hujan dengan Tinjauan Teknik Eksplorasi Terbaik pada Deret Data* (dibimbing oleh Nadjamuddin Harun, Muhammad Saleh Pallu, Andani Achmad)

Indonesia sebagai negara tropis memiliki curah hujan yang cukup tinggi. Peranannya dalam berbagai kehidupan manusia cukup vital, sehingga usaha untuk dapat memahami karakteristik sampai dengan memprediksi waktu serta durasi hujan menjadi penting sebagai informasi pendukung dan pengambilan keputusan. Dalam disertasi ini diteliti berbagai model prediksi hujan baik pendekatan statistik maupun kecerdasan buatan untuk kota Makassar berdasarkan unsur meteorologi yang tercatat di BMKG Makassar dari tahun 2001-2010.

Metode yang diusulkan dapat dikategorikan menjadi dua bagian berdasarkan keluaran prediksi yang diharapkan yaitu kuantitatif dan kualitatif. Pendekatan kuantitatif digunakan model prediksi *state of the art* yaitu pendekatan statistik ARIMA dan ASTAR serta hybrid kecerdasan buatan wavelet-NN dan GA-NN. Pendekatan Kualitatif menggunakan ANFIS, JST-Fuzzy dan usulan kebaruaran dalam penelitian ini yaitu SVM-Fuzzy. Sebelum pelatihan, unsur meteorologi terlebih dahulu diuji statistik korelasinya terhadap curah hujan. Dari hasil uji diputuskan Kelembaban, temperatur dan kecepatan angin sebagai input pelatihan karena memiliki korelasi tertinggi.

Keakuratan prediksi diukur dengan beberapa parameter berdasarkan pendekatannya. Prediksi dengan pendekatan kuantitatif divalidasi dari nilai prediksi curah hujan (mm/hr) yang diadaptasikan terhadap *trend chart* serta nilai *root mean square error* (RMSE). Sedangkan pendekatan kualitatif diukur dari persentase ketepatan logika samar menentukan rentang/kategori curah hujan serta deviasi prediksi terhadap aktual dalam bentuk *trend*.

Hasilnya menunjukkan ASTAR memiliki keakuratan prediksi yang lebih unggul dalam pendekatan kuantitatif dengan nilai RMSE terkecil serta *trend* prediksi terhadap aktual yang paling baik. Untuk pendekatan kualitatif, metode kebaruaran SVM-Fuzzy lebih unggul dari dua model lainnya dengan persentase prediksi mencapai 80% serta deviasi *trend* yang lebih baik.

ABSTRACT

INDRABAYU. *Expert System in Finding Best Exploration Techniques for Rainfall Forecasting Based on Data Series* (Supervised by Nadjamuddin Harun, Muhammad Saleh Pallu, Andani Achmad)

Indonesia is tropical country with high rainfall events. It has vital roles in almost living sectors. Hence, efforts in understanding and comprehending rain characteristic and duration have been conducting through many researches for decades. This dissertation aiming on finding best exploration methods from several predicting system, both from artificial intelligence and statistic approach. The prediction is based on empirical data series and using various meteorology parameters.

The elucidating of dissertation is divided into two categories i.e. quantitative and qualitative approaches. Both are using state of the art of hybrid artificial intelligence (AI) and statistic approach. In AI, wavelet-NN and GA-NN are implemented, while statistic approach incorporated ARIMA and ASTAR. Qualitative approach introducing ANFIS, Neural Network-Fuzzy Logic (NN-FL) and novelty proposed in this dissertation, Support Vector Machine-Fuzzy Logic (SVM-FL). For optimum result and reducing time processing, correlation among meteorological parameters are conducted to find highest correlation to rain fall.

Accuracy are defined by some parameters depend on the research approach. Quantitative approach are validated based on accuracy in predicting quantitative value of rain fall (mm/h) and adapted to chart *trend* and root mean square error (RMSE). While qualitative approach are measured on precise percentage and rainfall category. The deviation between prediction and actual data can also be shown from *trend* chart.

The results shows ASTAR has higher accuracy with lowest RMSE and better matching pattern between actual and prediction. For qualitative approach the propose SVM-Fuzzy outperform the other methods which reach 80% accuracy and a better deviation *trend*.

DAFTAR ISI

PRAKATA	v
ABSTRAK	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR TABEL	xv
DAFTAR GAMBAR	xviii
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah	12
C. Tujuan Penelitian	12
D. Manfaat Penelitian	13
E. Pembahasan	14
BAB II TINJAUAN PUSTAKA	16
A. Proses Presipitasi (Hujan)	16
1. Hydrologic Cycle	16
2. Evaporasi (Penguapan)	18
3. Hujan	20
B. Klasifikasi Hujan	23
C. Curah Hujan	27

D. Pengukuran Curah Hujan Menggunakan *Rain Gauge* ..28

1. *Rain Gauge Non Recording*..... 28
2. *Rain Gauge Recording*..... 29

E. Pengukuran Curah Hujan Menggunakan Radar dan Satelit 32


F. Menentukan Besaran Curah Hujan 33

G. Peramalan Curah Hujan 36

1. *Time-Series* 37
2. Analisis Regresi..... 40
3. ARIMA (*Auto Regressive integrated Moving Average*) 40
4. ANN (*Artificial Neural Network*)..... 42
5. *Hidden Layer dan Neuron* 46
6. *Algoritma Back Propagation* 46
7. Fungsi Aktivasi..... 47
8. *Preprocessing dan Postprocessing* 49
9. Training Pada *Back Propagation* 50

H. Variabel Data untuk Peramalan Curah Hujan..... 53

1. Intensitas Sinar Matahari..... 53
2. Temperatur 55
3. Kelembaban Udara..... 57
4. Tekanan Udara 58



5. Angin.....	60
6. Curah Hujan.....	62
I. Kerangka Pikir Penelitian	64
BAB III METODE PENELITIAN	66
A. Pengumpulan Data.....	66
1. Jenis data	66
2. Teknik Pengambilan Data	69
3. Metode Analisis.....	73
B. Metodologi.....	75
C. ARIMA (<i>Autoregressive Integrated Moving Average</i>)....	77
1. Metode ARIMA.....	78
2. Stasioneritas Data	79
3. Tahapan Metode ARIMA.....	80
4. Menentukan Hubungan Parameter Meteorologi terhadap Curah Hujan dengan Analisis Regresi Berganda.....	82
D. ASTAR (<i>Adaptive Splines Threshold Autoregression</i>) ..	84
1. Prediksi Curah Hujan Dengan Metode Astar.....	84
2. Basis Fungsi	85
3. Verifikasi dan Validasi Model.....	87
E. <i>GENETIC ALGORITHM-NEURAL NETWORK (GA- NN)</i>	87

1. Pelatihan Dan Pengujian Jaringan Untuk Prediksi Variabel Input Dengan <i>Backpropagation</i>	88
2. Validasi Curah Hujan Dengan <i>Genetic Algorithm-Neural Network</i>	90
F. Wavelet-NN	96
1. Proses Pelatihan <i>Wavelet-Neural Network</i>	97
2. Pengolahan Data Inputan	98
3. Neural Network	99
4. Proses Prediksi <i>Wavelet-Neural Network</i>	100
G. ANFIS	101
1. Pengolahan Data	102
2. Pengaturan Parameter Awal Pelatihan dan Pengujian ANFIS	102
3. Pelatihan dan Pengujian Data Pada ANFIS	103
4. Evaluasi Model ANFIS	104
5. <i>Root Mean Square Error (RMSE)</i>	104
H. Fuzzy	105
1. Perancangan <i>Fuzzy Logic</i>	105
2. Penentuan <i>Space Data</i> Dengan Metode <i>Fuzzy Cluster Means</i>	106
3. Fuzzifikasi	107
4. <i>Rule base</i>	108

5. Inferensi <i>Fuzzy</i>	109
6. Defuzzifikasi.....	110
7. Pengujian Sistem Prediksi dan Analisa	110
I. <i>Support Vector Machine – Fuzzy Logic (SVM-FL)</i>	111
1. Proposed System	111
2. Unjuk Kerja Sistem	112
BAN IV HASIL DAN PEMBAHASAN.....	115
A. Analisis Korelasi Variabel Input.....	115
B. Distribusi Data Curah Hujan Berdasarkan Rekamaya Hidrologi	117
C. Hasil Prediksi Curah Hujan Tahunan Metode Kuantitatif	120
1. ARIMA (<i>Autoregressive Integrated Moving Average</i>).....	120
2. ASTAR (<i>Adaptive Splines Threshold Autoregression</i>).....	128
3. <i>Genetic Algorithm–Neural Network</i>	136
4. <i>Wavelet - Neural Network</i>	141
D. Hasil Prediksi Curah Hujan Tahunan Metode Kualitatif	144
1. ANFIS (<i>Adaptive Neuro Fuzzy Interference System</i>)	144

2. <i>Neural Network - Fuzzy</i>	148
3. <i>SVM (Support Vector Machine) – Fuzzy</i>	153
E. Perbandingan Hasil Prediksi Metode Kuantitatif.....	158
1. <i>Analisis Trend</i>	158
2. <i>Persentase Keakuratan</i>	165
F. Perbandingan Hasil Prediksi Metode Kualitatif.....	166
1. <i>Analisis Trend</i>	166
2. <i>Persentase Keakuratan</i>	172
G. Parameter Terbaik Untuk Sistem Prediksi pada Kuantitatif dan Kualitatif.....	173
H. <i>Potensi Penelitian Selanjutnya</i>	182
BAB V KESIMPULAN DAN SARAN.....	184
A. <i>Kesimpulan</i>	185
B. <i>Saran</i>	186
DAFTAR PUSTAKA.....	186
LAMPIRAN.....	

DAFTAR TABEL

nomor	halaman
1. Hasil pengujian HyBMG Kota Banjarbaru (Sanjaya dkk, 2009)	8
2. Klasifikasi curah hujan menurut standar internasional (WMO)	63
3. Basis aturan prediksi hujan	108
4. Hasil uji koefisien determinasi (r^2) parameter tahun 2004-2008	116
5. Koefisien korelasi antara 2 variabel	116
6. Perhitungan kuadrat data tinggi hujan	118
7. variabel dalam perhitungan distribusi frekuensi metode <i>Chi Square</i>	120
8. Distribusi frekuensi curah hujan dengan metode <i>Chi Square</i>	120
9. <i>Difference</i> pertama kelembaban bulan Februari tahun 2004-2008	121

10. Hasil prediksi kelembaban bulan Februari Tahun 2009 dan 2010	125
11. Prediksi temperatur, kelembaban, angin 1 Februari 2009 ..	126
12. Hasil prediksi curah hujan menggunakan metode ARIMA, bulan Januari 2009 dan 2010.....	126
13. Jumlah basis fungsi tahun 2009 dengan variabel Y terhadap X	129
14. Jumlah basis fungsi tahun 2010 dengan variabel Y terhadap X	129
15. Model variabel respon Y terhadap X Tahun 2009.....	131
16. Model variabel respon Y terhadap X Tahun 2010.....	131
17. Nilai Kepentingan Tahun 2009 X terhadap Y.....	131
18. Nilai Kepentingan Tahun 2010 X terhadap Y.....	132
19. Hasil prediksi curah hujan menggunakan metode ASTAR Januari.....	135
20. Hasil prediksi metode NN, contoh: temperatur pada bulan Maret.....	137
21. Hasil prediksi metode NN untuk variabel input tahun 2009 dan 2010	138
22. Hasil prediksi curah hujan menggunakan metode GA-NN, Contoh: Curah hujan bulan Januari 2009.....	140
23. Hasil prediksi curah hujan menggunakan metode <i>Wavelet Neural Network</i> bulan Januari 2009 dan 2010.....	142

24. Hasil prediksi temperatur bulan Mei tahun 2010.....	144
25. Hasil prediksi curah hujan kualitatif menggunakan metode ANFIS bulan November Tahun 2009 dan 2010.....	145
26. Validasi hasil prediksi hujan sistem ANFIS Observasi tahun 2009	147
27. Validasi hasil prediksi hujan sistem ANFIS dan aktual tahun 2010	147
28. Hasil prediksi temperatur dengan metode NN bulan Mei 2010	148
29. Hasil <i>cluster</i> data rata-rata per hari tahun 2004 - 2008	151
30. Hasil prediksi curah hujan kualitatif dengan metode NN <i>Fuzzy</i> untuk bulan November 2009 dan 2010.....	152
31. Validasi hasil prediksi hujan sistem <i>Fuzzy logic</i> dengan keadaan sebenarnya tahun 2009.....	152
32. Perbandingan hasil prediksi parameter temperatur dengan metode <i>Support Vector Machine</i> dengan data aktual bulan November tahun 2009.....	154
33. Hasil prediksi curah hujan kualitatif menggunakan metode SVM <i>Fuzzy</i> , bulan November tahun 2009 dan 2010	155
34. Keakuratan prediksi dengan metode <i>Support Vector Machine-Fuzzy Logic</i> tahun 2009	157
35. Perbandingan hasil prediksi curah hujan metode kuantitatif bulan Januari 2009	159

36. Perbandingan hasil prediksi curah hujan metode kuantitatif bulan Januari 2010	160
37. Perbandingan nilai RMSE	165
38. Perbandingan hasil prediksi curah hujan metode kualitatif bulan November 2009.....	167
39. Perbandingan hasil prediksi curah hujan metode kualitatif bulan November 2010.....	168
40. Perbandingan nilai % keakuratan tahun 2009	172
41. Hasil <i>cluster</i> data rata-rata per hari tahun 2004 - 2008	182

DAFTAR GAMBAR

nomor	halaman
1. Parameter dan metode data eksisting	11
2. Diagram skematik dari global <i>hydrologic cycle</i> (McCuen, 1998)	16
3. Proses hujan sebagai rangkaian dari <i>hydrologic cycle</i> (Brian J. Knap, 1979)	20
4. Bagan proses hujan sederhana (olahan sendiri)	20
5. Variasi eksponensial tekanan uap saturasi dengan temperatur udara (Dawei Han: 2010)	22

6. Proses <i>orographic</i> presipitasi (Ragunath, 2007).....	24
7. Proses terjadinya frontal surface lifting (Ragunath, 2007)	24
8. Proses terjadinya <i>convective lifting</i> (Lundquist, 2010).....	25
9. Perbandingan radius, volume dan kecepatan inti awan dan titik hujan (Elizabeth Shaw, 1994)	25
10. Proses keseluruhan dan parameter yang mempengaruhi hujan (Modifikasi dari Lunquist, 2010)	26
11. <i>Rain gauge symon</i> (Ragunath, 2007)	29
12. <i>Rain gauge tipping bucket</i> (Ragunath, 2007)	30
13. <i>Rain gauge tipe weighing</i> (Ragunath, 2007)	31
14. <i>Rain gauge tipe float</i> (Ragunath, 2007)	31
15. Kurva massa curah hujan (Ragunath, 2007).....	32
16. Bentuk display radar. (a) PPI (b) RHI (P.J.M de Laat et.al., 1976)	33
17. Metode Thiessen (P.J.M de Laat et.al., 1976).....	34
18. Perbandingan Metode Thiessen (a) dan Metode Kriging (P.J.M de Laat et.al., 1976)	35
19. Metode Isohyetal (P.J.M de Laat et.al., 1976)	35
20. Klasifikasi Metode Time Series (Timo Terasvirta, et, al., 2010)	38
21. Konsep artificial neuron (Gershenson, 2003)	44
22. Proses pelatihan ANN (Demuth, 2009).....	45
23. Detail ANN (Zhang, 2004a)	45

24. Fungsi aktivasi sigmoid logistic (<i>Demuth, 2009</i>).....	48
25. Fungsi aktivasi sigmoid tangent (<i>Demuth, 2009</i>)	48
26. Fungsi aktivasi linier (<i>Demuth, 2009</i>).....	49
27. Wilayah Indonesia berdasarkan pola hujan (<i>Istriana, 2009</i>) .	64
28. Kerangka pikir penelitian	65
29. Grafik curah hujan rata-rata Kota Makassar tahun 2004- 2009	68
30. Termometer	69
31. Barometer	70
32. <i>Barograph</i>	71
33. <i>Anemograph</i>	71
34. Anemometer dan penunjuk arah angin	72
35. <i>Campbell stokes</i>	72
36. Penakar hujan (a) tipe Obs (b) tipe Hillman	73
37. Metode yang digunakan dalam penelitian.....	76
38. Langkah-langkah penelitian secara umum.....	77
39. <i>Flowchart</i> prediksi dengan metode ARIMA	78
40. <i>Flowchart</i> dengan analisis regresi berganda	83
41. <i>Flowchart</i> prediksi curah hujan metode ASTAR	85
42. <i>Flowchart</i> penelitian dengan metode GA-NN	89
43. <i>Flowchart</i> perancangan sistem <i>Genetic Algorithm-Neural Network</i>	90
44. <i>Flowchart</i> pelatihan <i>Wavelet Neural Network</i>	97

45. <i>Flowchart</i> penelitian dengan metode ANFIS	101
46. <i>Flowchart</i> perancangan sistem <i>Fuzzy logic</i>	106
47. Kombinasi SVM dan <i>Fuzzy Logic</i>	112
48. Posisi <i>rule base</i> pada alur <i>Fuzzy logic</i>	112
49. <i>Flowchart</i> SVM- <i>Fuzzy Logic</i>	113
50. Grafik curah hujan tinggi pada periode ulang	119
51. Grafik koefisien autokorelasi pembeda pertama kelembaban.....	123
52. Koefisien parsial autokorelasi pembeda pertama kelembaban.....	123
53. Grafik perbandingan hasil prediksi curah hujan menggunakan metode ARIMA (a) Januari 2009 ; (b) Januari 2010.....	128
54. Grafik perbandingan hasil prediksi curah hujan menggunakan metode ASTAR dengan data aktual (a) Januari 2009 ; (b) Januari 2010	134
55. Grafik pemerakan nilai <i>fitness</i> prediksi curah hujan bulan Januari 2009	139
56. Metode GA-NN dengan data real (a) Januari 2009 ; (b) Januari 2010	141
57. Grafik perbandingan hasil prediksi curah hujan menggunakan metode <i>Wavelet</i> NN dengan data aktual (a) Januari 2009; (b) Januari 2010	143

58. Grafik perbedaan hasil prediksi metode kuantitatif Januari 2009	162
59. Grafik perbedaan hasil prediksi metode kuantitatif Januari 2010	162
60. Grafik perbandingan metode kuantitatif tahun 2009.....	163
61. Grafik perbandingan metode kuantitatif tahun 2010.....	164
62. Grafik perbedaan hasil prediksi metode kualitatif November 2009	169
63. Grafik perbedaan hasil prediksi metode kualitatif November 2010	169
64. Grafik perbandingan metode kualitatif tahun 2009.....	170
65. Grafik perbandingan metode kualitatif tahun 2010.....	171
66. <i>Cluster</i> 1 temperatur rendah.....	174
67. <i>Cluster</i> 2 temperatur sedang	175
68. <i>Cluster</i> 3 temperatur tinggi	176
69. <i>Cluster</i> 1 kelembaban rendah.....	177
70. <i>Cluster</i> 2 kelembaban sedang	178
71. <i>Cluster</i> 3 kelembaban tinggi	179
72. <i>Cluster</i> 1 kecepatan angin ringan.....	180
73. <i>Cluster</i> 2 kecepatan angin sedang	180
74. <i>Cluster</i> 3 kecepatan angin kencang	181
75. <i>Cluster</i> 4 kecepatan angin sangat kencang	182
76. Hubungan temperatur luar dengan curah hujan	183

77. Hubungan kec. angin, kelembaban dan curah hujan 184



DAFTAR LAMPIRAN

nomor	halaman
1. Data meteorologi dari BMKG.....	193
2. Pembagian zona musim di Sulawesi.....	206
3. Korelasi variabel yang mempengaruhi curah hujan.....	207
4. a. Data perbandingan hasil prediksi tahun 2009	209

b. Data perbandingan hasil prediksi tahun 2010	218
5. Pseudocode untuk program SVM-Fuzzy	227
6. Perhitungan dalam rekayasa hidrologi berkenaan dengan curah hujan.....	231



BAB I

PENDAHULUAN

A. Latar Belakang

Kota Makassar merupakan kota terbesar keempat di Indonesia dan terbesar di Kawasan Timur Indonesia. Kota ini memiliki luas areal 175,79 km² dengan jumlah penduduk berkisar 1,3 juta orang, sehingga kota ini sudah menjadi kota metropolitan. Secara geografis Kota Metropolitan Makassar terletak di pesisir Pantai Barat Sulawesi-Selatan pada koordinat 119°18'27,97" - 119°32'31,03" Bujur Timur dan 5°00'30,13" - 5°14'6,49" Lintang Selatan dan secara administratif berbatasan dengan daerah berikut:

- Batas utara : Kabupaten Pangkajene Kepulauan
- Batas timur : Kabupaten Maros
- Batas selatan : Kabupaten Gowa
- Batas barat : Selat Makasar

Sebagaimana kota lainnya di Indonesia, Kota Makassar dipengaruhi dua musim yaitu musim hujan periode Oktober-April dan musim kemarau periode Mei-September. Informasi cuaca dan iklim merupakan kebutuhan utama untuk mendukung kegiatan di berbagai sektor, utamanya yang berkenaan dengan sumber daya air. Informasi tersebut dapat berupa prediksi curah hujan. Berbagai metode prediksi telah dikembangkan hingga saat ini.

Sistem prediksi tersebut umumnya didasarkan pada prinsip proses evatransporasi yaitu proses pembentukan awan hujan yang dipengaruhi oleh parameter meteorologi lainnya. Sehingga dalam proses pelatihan, sistem membutuhkan data empiris meteorologi yang biasanya melibatkan puluhan tahun data bergantung pada resolusi waktu yang akan diramalkan.

Saat ini penelitian dalam membuat sistem prediksi curah hujan yang berdasarkan prinsip evatransporasi yang menggunakan data seri empiris meteorologi banyak dilakukan dengan pendekatan kuantitatif. Selain itu prediksi lebih banyak untuk prediksi curah hujan tahunan, bulanan dan yang terkecil adalah harian. Pendataan dan ramalan cuaca dan iklim secara nasional dilakukan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) menggunakan berbagai metode diantaranya pendekatan statistik seperti model regresi dan *Autoregressive Integrated Moving Average* (ARIMA), ataupun dengan memanfaatkan kecerdasan buatan seperti jaringan saraf tiruan, *Fuzzy Logic*, Algoritma Genetik, Support Vector Machine, Transformasi *Wavelet*, *Adaptive Neuro-Fuzzy Inference System* (ANFIS), atau kombinasi dari beberapa metode tersebut. Akan tetapi setiap pendekatan dalam prediksi hujan memiliki nilai *trade-off* yang sangat bergantung kepada parameter masukan untuk prediksi dan tentunya tempat atau lokasi yang akan diprediksi.

Berdasarkan data BMKG Kota Makassar, ada 6 parameter yang digunakan untuk memprediksi hujan saat ini yaitu:

- Curah hujan sebelumnya (mm/hr)
- Temperatur udara (°C)
- Intensitas penyinaran matahari (%)

- Tekanan udara (mB)
- Kelembaban nisbi (%)
- Arah angin (knot)

Beberapa penelitian terkait menunjukkan hubungan parameter meteorologi di atas terhadap probabilitas terjadinya hujan. Berikut ini akan dibahas penelitian-penelitian sebelumnya baik dari sistem prediksi maupun dari parameter meteorologi yang diamati. Dari studi penelitian sebelumnya akan diperoleh *insight* dari *state of art* penelitian dan menjadi titik acuan dalam disertasi ini untuk mencapai kebaruan (*novelty*).

1. Penelitian Terkait Korelasi Unsur Meteorologi Terhadap Curah Hujan

Ada banyak variabel yang dapat mempengaruhi terjadinya hujan yang tentunya akan berbeda bergantung pada lokasi/wilayah yang diamati. Perbedaan variabel ini bahkan kadang sebagai anomali dimana suatu variabel tertentu yang dianggap sebagai pembentuk hujan dapat berbanding terbalik hasilnya (Rumar, A. dkk, 2004). Variabel *Sea Surface Temperature* (SST) berbeda trend-nya pada daerah tropis dan subtropis. Penelitian tersebut menyebutkan SST berbanding terbalik dengan curah hujan di daratan untuk daerah tropis. Aktifitas *lanthropogenic* dan *El Niño-southern oscillation* (ENSO) dianggap sebagai kontributor hal ini.

Penelitian tersebut sebelumnya telah dilakukan oleh (Aldrian, E., dkk, 2003) yang meninjau hubungan *El Niño-southern oscillation* (ENSO) dan SST. Hasilnya telah diuraikan yaitu terbentuknya 3 tipe hujan di wilayah

Indonesia. Penelitian lanjutan terhadap prediksi hujan di Indonesia menyatakan bahwa suhu pada permukaan troposfer juga berperan sehingga diperlukan *adjustment* terhadap peta pengaruh ENSO di Indonesia (Giannini dkk, 2007).

Penelitian yang menggunakan cukup banyak variabel pendukung dilakukan di Timika Indonesia (Region C). Dalam penelitian ini (Aldnan dkk, 2008) memanfaatkan 4 variabel data empiris yaitu:

- Curah hujan (mm)
- *Land surface temperature*, LST, (oC)
- *Surface pressure* (mBAr)
- Kelembaban Nisbi (%)

Keempat variabel tersebut ternyata memberikan pengaruh signifikan dalam prediksi curah hujan pada region C.

2. Penelitian terkait Sistem Prediksi Yang Digunakan

Dalam peramalan biasanya digunakan metode statistik ataupun model kecerdasan buatan seperti *Artificial Neural Network (ANN)*. Model ANN didasarkan pada prediksi oleh analisis cerdas terhadap *trend* dari himpunan data historis yang telah ada. *Artificial Neural Network* memiliki kemampuan untuk model sistem linear maupun non linear tanpa membuat asumsi apapun dan kemampuan untuk belajar dan menggeneralkan data yang diberikan untuk menghasilkan solusi yang berguna, meskipun data input mengandung *error* atau tidak lengkap.

Kekurangan dari metode ini dalam meramalkan hujan adalah kompleksitas interaksi antara atmosfer dan lautan serta ketidakpastian hubungan antara curah hujan dan variabel *hydrometeorology*, sehingga perlunya memahami proses hujan serta parameter yang mempengaruhinya adalah penting untuk mendapatkan hasil ramalan yang seakurat mungkin.

Model ANN yang paling banyak digunakan (lebih 80 %), untuk peramalan hujan adalah konfigurasi algoritma *Back Propagation*. Terdapat beberapa penelitian yang menggunakan ANN untuk peramalan hujan, sebuah karya pelopor dalam menerapkan ANN untuk peramalan curah hujan dilakukan oleh French et al. (1992), yang menggunakan ANN untuk meramalkan dua dimensi curah hujan 1 jam ke depan. Parameter yang digunakan adalah data curah hujan yang dihasilkan oleh model simulasi curah hujan matematika sebagai masukan untuk *training set* data. Keterbatasan dari penelitian ini adalah adanya *trade-off* antara interaksi dan waktu pelatihan yang tidak mudah seimbang. Jumlah lapisan tersembunyi (*hidden layer*) dan node tersembunyi tampaknya tidak cukup, dibandingkan dengan jumlah input dan output node.

Namun hal itu telah dianggap sebagai kontribusi pertama untuk aplikasi ANN dan mendirikan sebuah tren baru dalam memahami dan mengevaluasi peran ANN dalam menyelidiki proses geofisika yang kompleks.

Seiring perkembangan model algoritma pada metode ANN, maka semakin banyak penelitian dalam peramalan curah hujan yang dilakukan dengan hasil yang semakin akurat, sebagai contoh penelitian-penelitian berikut:

- a. Abhishek K, et al (2012) telah melakukan prediksi curah hujan menggunakan ANN dengan menggunakan 400 entri data input dan output untuk 8 bulan dalam *range* tahun 1960 – 2010 (50 tahun), penelitian ini menggunakan kelembaban rata-rata dan kecepatan angin rata-rata sebagai parameter input dalam menentukan curah hujan sebagai parameter output yang diharapkan. Selain itu penelitian ini menguji 3 model algoritma yaitu *Back Propagation Algorithm*, *Layer Recurrent Network* dan *Cascade Back-Propagation*. Hasilnya di antara ketiga algoritma yang diuji, *Back Propagation Algorithm* memiliki nilai *error* yang paling kecil, sehingga merupakan algoritma terbaik dari ketiganya.
- b. Ramírez Maria Cleofe´ Valverde, et al (2005) melakukan penelitian untuk meramalkan curah hujan menggunakan ANN pada daerah Sao Paulo. Penelitian ini menggunakan model *Feed Forward Neural Network* dan *Resilient Propagation Learning Algorithm*. Parameter meteorologi yang digunakan mengacu pada model ETA yaitu temperatur potensial, angin, kelembaban, temperatur udara, endapan air, vortisitas relatif dan fluks kelembaban divergensi. Penelitian ini juga menyajikan perbandingan penggunaan *Multiple Linear Regression* dan ANN dengan hasil keunggulan dalam penggunaan ANN.
- c. Sanjaya, et. al (2009) hanya menggunakan satu parameter saja yaitu curah hujan sebelumnya. Hasil yang diperoleh juga dalam bentuk kuantitatif yaitu curah hujan prediksi (mm/hr). Pendataan dan ramalan cuaca dan iklim secara nasional dilakukan oleh Badan Meteorologi Klimatologi dan Geofisika (BMKG) menggunakan berbagai metode diantaranya

pendekatan statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Time Series Analisis* (TISEAN), ataupun dengan memanfaatkan kecerdasan buatan seperti Tranformasi *Wavelet* dan *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Akan tetapi metode ARIMA paling sering digunakan dalam peramalan karena kemudahan komputasinya. Hasil validasi keempat metode menunjukkan keakuratan yang berbeda di setiap lokasi. Untuk tipe muson (monsun) digunakan data empiris curah hujan dari stasiun Banjarbaru (tahun 1974-2008). Ada 4 model prediksi yang sudah diterapkan pada sistem HyBMG yaitu:

- 1) *Adaptive Neural Fuzzy Inference System* (ANFIS)
- 2) Transformasi wavelet
- 3) *Autoregressive Integrated Moving Average* (ARIMA)
- 4) *Time Series Analisis* (TISEAN)

Dalam menentukan baik tidaknya suatu model prediksi digunakan dua variabel uji yaitu *root mean square error* (RMSE) dan korelasi r . Semakin kecil nilai RMSE menunjukkan nilai deviasi kesalahan yang kecil antara data prediksi dan observasi begitu pula sebaliknya. Hasilnya terlihat pada Tabel 1.

Tabel 1. Hasil pengujian HyBMG Kota Banjarbaru (Sanjaya dkk, 2009)

Tahun	Metoda Prakiraan			
	ANFIS	WAVELET	ARIMA	TISEAN
1999	104	58	62	117
2000	117	90	86	81
2001	71	62	49	88
2002	80	98	86	105
2003	124	104	114	120
2004	115	103	92	79
2005	105	55	57	114
2006	101	68	73	64
2007	97	106	105	77
2008	116	100	113	115
1999 - 2008	104	87	86	98
r	0,68	0,78	0,79	0,71

Model wavelet dan ARIMA memberikan hasil prediksi lebih baik. Baik ditinjau dari nilai RMSE yang rata-rata lebih kecil serta nilai korelasi r yang lebih besar dibandingkan dengan kedua metode lainnya.

Ada 2 hal yang belum dirumuskan pada penelitian *Sanjaya dkk*, yaitu tidak dimanfaatkannya pengaruh variabel lain seperti suhu permukaan (*land surface temperature* dan *sea surface temperature*), kelembaban, kecepatan angin dan lain-lain sebagai variabel masukan untuk prediksi. Padahal data dari variabel-variabel tersebut tersedia di BMKG. Selain itu model-model prediksi terbaru belum terintegrasi ke dalam HyBMG seperti *Particle Swormp*, algoritma semut, algoritma genetik, *Support Vector Machine*, dan lain-lain.

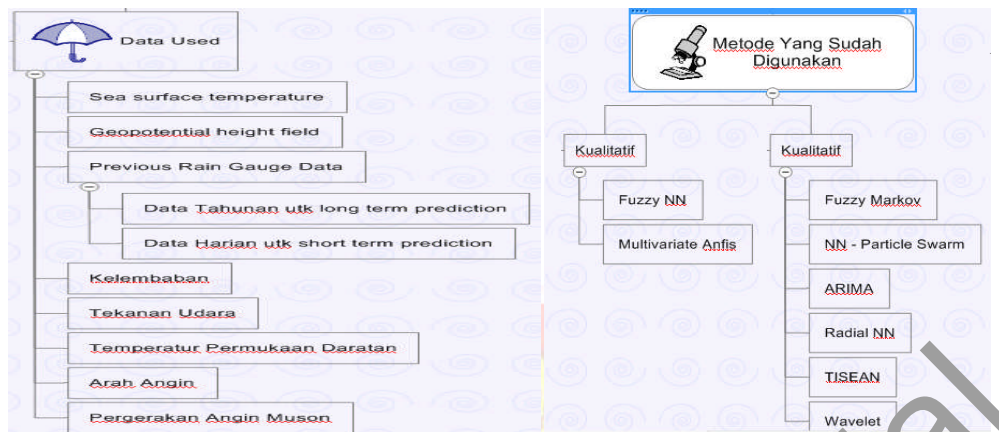
- d. Manusthiparom, et al. (2003) meneliti hubungan EL Nino, Indeks SOI (*Southern Oscillation Indices*) dan SST (*Sea Surface Temperature*)

terhadap curah hujan bulanan di Chiang Mai, Thailand dan menemukan hubungan yang *significant* di antara variabel-variabel tersebut. Sehingga parameter input yang digunakan dalam peramalan hujan satu tahun ke depan adalah SOI, SST dan curah hujan masa lalu. Penelitian ini menggunakan algoritma *Back Propagation* dan menyarankan untuk mengadopsi beberapa variabel iklim yang berhubungan dengan hujan sebagai prediktor tambahan seperti kecepatan angin, keadaan mendung/berawan, temperatur permukaan dan tekanan udara.

- e. *Hung, NQ, et.al.* (2009) juga melakukan peramalan curah hujan menggunakan ANN di Bangkok, Thailand dengan menggunakan model *Generalized Feed Forward* dan fungsi tangen hiberbolik. Penelitian ini memiliki data yang diperoleh selama 3 tahun (1997 – 1999) untuk peramalan hujan 1 – 6 jam ke depan dengan kelembaban relatif, tekanan udara, suhu bola basah, dan keadaan mendung sebagai parameter input.
- f. *Gan, X, et.al.* (2011) menggunakan MATLAB *Neural Network* dalam mereproduksi model hujan pada China bagian timur. Model yang diadopsi adalah *Back Propagation Algorithm* dengan 3 lapisan (*layer*) di mana pada lapisan output menggunakan fungsi aktivasi logsig dan pada lapisan tersembunyi (*Hidden Layer*) menggunakan tansig. Variabel input yang digunakan adalah curah hujan bulan April, intensitas dingin bulan Januari dan kelembaban pada bulan Februari. Pemilihan variabel ini didasarkan pada faktor korelasi terbesar saat menggunakan *Corrcoef Function* yang merupakan salah satu fungsi di MATLAB.

- g. Teknik JST akan semakin baik jika dikombinasikan dengan metode lainnya. Dalam sistem peringatan dini banjir di Kota Hainan China digunakan kombinasi JST dan *Fuzzy* (Wu, H dkk, 2009).
- h. Penelitian serupa dilakukan di kota Sanjiang (Hongxia L, Chuanwei L, 2008). JST berfungsi sebagai prediktor curah hujan dengan angka kuantitatif dan selanjutnya *Fuzzy* mentransformasi angka kuantitatif menjadi kualitatif.
- i. Teknik algoritma genetik juga dapat dikombinasikan dengan JST (Lin K, dkk, 2008). Model ini biasa disingkat dengan GANN (*Genetic Algorithm - Neural Network*). Esensinya adalah memberikan masukan ke JST setelah melewati proses seleksi genetik GA.
- j. Yang terakhir dan cukup menjanjikan adalah penggabungan JST-Wavelet pada prediksi pembebanan listrik di Inggris (Chen Y, dkk, 2010). Seperti diketahui pada pembahasan sebelumnya bahwa wavelet telah diuji dengan HyBMG sebagai teknik terbaik untuk prediksi hujan di Indonesia. Dengan dikombinasikan dengan JST maka diharapkan hasilnya akan lebih baik dari sistem yang sudah ada.

Dari berbagai penelitian tersebut di atas dapat dirangkum beberapa parameter yang memiliki korelasi terhadap besarnya curah hujan yang akan terjadi. Parameter-parameter tersebut antara lain:



Gambar 1. Parameter dan metode data eksisting

Penelitian ini akan menguji berbagai parameter yang berkorelasi terhadap tingkat curah hujan dan menentukan parameter dengan korelasi tertinggi sebagai acuan untuk memprediksi curah hujan yang akan terjadi. Selain itu akan diuji beberapa model prediksi baik pendekatan statistik maupun kecerdasan buatan untuk mendapat model terbaik yang sesuai untuk prediksi curah hujan di Kota Makassar. Pengujian model prediksi yang dilakukan meliputi peramalan berdasarkan pendekatan kuantitatif yaitu Jaringan Saraf Tiruan (JST), Tranformasi *Wavelet* kombinasi dengan JST, Algoritma Genetik (GA) kombinasi dengan JST dan peramalan statistik melalui *Autoregressive Integrated Moving Average* (ARIMA) dan *ASTAR (Adaptive Splines Threshold Autoregression)*, sedangkan pengujian berdasarkan pendekatan kualitatif yaitu *Adaptive Neuro-Fuzzy Inference System* (ANFIS), JST kombinasi dengan Logika Fuzzy dan *Super Vektor Machine* (SVM) kombinasi dengan Logika Fuzzy. *Novelty* yang akan diteliti adalah kombinasi maupun modifikasi model prediksi dan masukan data yang akan difokuskan

pada parameter dengan korelasi tertinggi terhadap tingkat curah hujan untuk mendapatkan hasil prediksi terbaik. Untuk itu dalam disertasi ini akan diangkat judul “SISTEM PAKAR UNTUK PREDIKSI CURAH HUJAN DENGAN TINJAUAN TEKNIK EKSPLOKORASI TERBAIK PADA DERET DATA”.

B. Rumusan Masalah

Berdasarkan uraian di atas sebelumnya bahwa diperlukan suatu model pendekatan prediksi yang paling tepat untuk kota Makassar. Untuk pencapaian hal tersebut maka dapat dirumuskan permasalahan sebagai berikut:

1. Menemukan parameter yang paling sesuai untuk digunakan dalam memprediksi curah hujan dari keanekaragaman parameter meteorologi yang ada dari hubungan sebab akibat dan korelasinya.
2. Membangun ulang metode eksisting yang sudah ada untuk diuji kembali dengan data meteorologi Makassar sekaligus menjadi pembandingan bagi metode kebaruan yang diusulkan dalam disertasi ini.
3. Menemukan sistem prediksi terbaik baik dari pendekatan kuantitatif maupun kualitatif untuk kota Makassar.
4. Pengamatan dan analisis waktu sampling dari unsur meteorologi yang sudah ada (harian) dan hipotesis diperlukannya *sampling* waktu yang lebih pendek atau panjang untuk hasil prediksi yang lebih baik.

C. Tujuan Penelitian

Berdasarkan permasalahan yang telah dirumuskan sebelumnya maka tujuan dari penelitian yang akan dilakukan adalah:

1. Melakukan investigasi terhadap variabel-variabel yang mempengaruhi curah hujan khususnya di Kota Makassar. Akan dilakukan uji korelasi terhadap parameter masukan yang digunakan oleh BMKG selama ini. Variabel-variabel yang diuji juga ditinjau dari tingkat pengaruh atau seberapa signifikan sinyal terhadap butiran hujan termasuk di dalamnya pengaruh waktu pengambilan sampel dari variabel.
2. Membuat sistem prediksi curah hujan untuk Kota Makassar dengan menggunakan beberapa model yang sudah ada sebelumnya. Beberapa sistem prediksi yang akan dibuat meliputi model pendekatan statistic serta pendekatan kecerdasan buatan.
3. Melakukan analisis terhadap perbandingan metode eksisting dan metode baru yang diusulkan ditinjau dari pendekatan kuantitatif maupun kualitatif. Unjuk kerja sistem diukur dari parameter tren, validitas linieritas, persentase keakuratan serta *Root Mean Square Error (RMSE)*.
4. Memperoleh *insight* atas kesesuaian metode sampling data yang telah dilakukan oleh BMKG selama ini dan rekomendasi akan perbaikan pengambilan sampling data jika diperlukan.

D. Manfaat Penelitian

Penelitian ini akan member manfaat kepada masyarakat umum di Kota Makassar dan diharapkan dapat diimplementasikan ke dalam sistem di BMKG. Uraian manfaat penelitian secara khusus sebagai berikut:

1. Ditemukannya variabel yang paling berperan untuk memprediksi curah hujan sehingga mempermudah dan mengefisienkan pengambilan data selanjutnya. Stasiun-stasiun cuaca dapat diperbaiki keakurasian nya pada variabel yang mempunyai korelasi signifikan terhadap curah hujan.
2. Diperolehnya gambaran menyeluruh terhadap perbandingan model-model prediksi eksisting secara ekstensif.
3. Model modifikasi ataupun kombinasi dapat memberikan hasil prediksi yang lebih baik dari model-model yang sudah ada.
4. Memungkinkan model pendetektor prediksi kualitatif yang dapat dikembangkan dalam penelitian ke depannya terutama dalam bidang sumberdaya air.

Dan uraian manfaat penelitian secara umum sebagai berikut:

1. Prediksi Hujan Harian yang lebih akurat untuk mendukung kegiatan harian masyarakat.
2. kedepannya dapat digunakan untuk aplikasi *decision support system* sumber daya air.
3. Dapat menjadi informasi pendukung bagi BMKG dalam bidang pertanian, seperti waktu yang tepat untuk cocok tanam dan lain-lain.

E. Kebaharuan

1. Perbandingan ekstensif dari ragam model kecerdasan buatan, statistik dan pengenalan pola, yang ditilik secara *holistic* mulai dari data *preprocessing* sampai dengan modifikasi teknik.
2. Usulan untuk menggunakan pendekatan kualitatif yang saat ini masih jarang diteliti akan tetapi sangat bermanfaat kedepannya untuk aplikasi-aplikasi teknik sumberdaya air. Teknik yang diusulkan adalah penggabungan *Support Vector Machine* (SVM) dan *Fuzzy Logic*.
3. *Insight* akan kemungkinan perlunya perbaikan ataupun perubahan dalam metode dan waktu pengambilan sampling unsur meteorologi yang sudah ada saat ini.



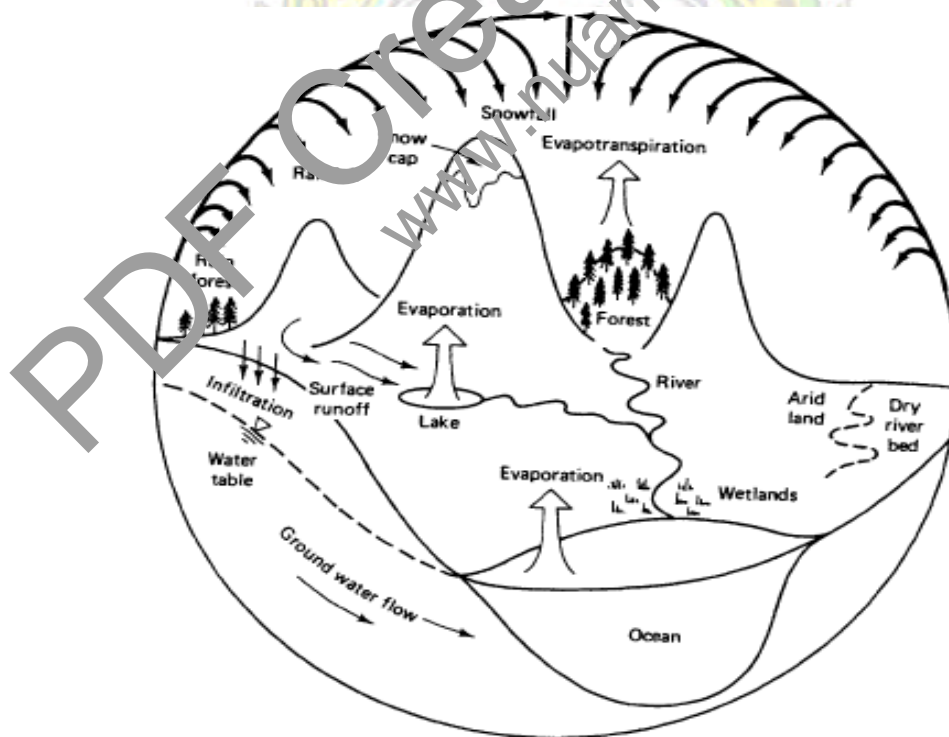
BAB II

TINJAUAN PUSTAKA

A. Proses Presipitasi (Hujan)

1. Hydrologic Cycle

Air bergerak antara lautan, *atmosphere*, *cryosphere* dan daratan. Jumlah air di bumi adalah konstan dalam skala waktu hingga ribuan tahun, namun terjadi perubahan bentuk dari bentuk cair, padat dan gas yang bergerak melalui lingkaran hidrologi (*Hydrologic Cycle*).



Gambar 2. Diagram skematik dari global *hydrologic cycle* (McCuen, 1998)

Jumlah air yang bergerak melalui *hydrologic cycle* setiap tahun sama dengan kedalaman 1 meter dari air yang menyebar secara merata di sepanjang permukaan bumi. Sejumlah air ini setiap tahun memasuki atmosfer melalui penguapan dan kembali ke bumi sebagai presipitasi. Untuk menguapkan 1 meter air dalam setahun dibutuhkan input energi rata-rata sebesar 80 Wm^2 .

Matahari menyediakan energi untuk menguapkan air dari permukaan. Ketika sudah berada di atmosfer, uap air dapat berpindah secara horizontal pada jarak yang jauh dan bergerak ke atas. Pergerakan horizontal dan vertikal dari uap air ini kritis terhadap keseimbangan air di daratan karena sekitar 1/3 dari presipitasi yang jatuh pada daratan adalah air yang telah diuapkan dari daerah lautan dan kemudian bergerak ke daratan.

Proses *hydrologic cycle* pada atmosfer merupakan proses presipitasi yaitu jatuhnya benda cair ataupun padat (hujan, salju dan es) dari atmosfer ke permukaan bumi. Di Indonesia, ataupun negara yang beriklim tropis, hujan merupakan bentuk presipitasi yang paling umum. Air hujan yang berada pada permukaan bumi akan menambah volume dari lautan ataupun terserap oleh wilayah daratan.

Proses selanjutnya yang masih merupakan rangkaian terakhir dari *hydrologic cycle* pada daratan dan lautan adalah dalam bentuk proses *evapotranspiration* yang merupakan proses yang mengembalikan air ke atmosfer.

Evapotranspiration terdiri dari dua bagian, yaitu evaporasi dan transpirasi. Evaporasi (Penguapan) adalah peristiwa hilangnya molekul air

dari massa tanah dan air yang disebabkan oleh energi panas matahari yang menyebabkan terjadinya penguapan, sementara transpirasi adalah peristiwa hilangnya air tumbuhan dalam bentuk penguapan.

2. Evaporasi (Penguapan)

Penguapan merupakan salah satu bagian penting dalam pembentukan presipitasi, karena banyaknya presipitasi dipengaruhi oleh proses evaporasi, sebagian besar uap air yang naik ke atmosfer disebabkan oleh penguapan. Ada beberapa variabel yang mempengaruhi proses ini, di antaranya:

- a. **Radiasi sinar matahari** yang memberikan kontribusi terbesar terhadap proses penguapan. Semakin tinggi radiasi sinar matahari, total penguapan akan semakin besar. Radiasi sinar matahari ditentukan oleh waktu dan garis lintang.
- b. **Angin** memiliki dua peran yang penting dalam menentukan *rate* penguapan. Pertama, angin menyalurkan panas yang terbentuk pada permukaan yang berdekatan, seperti gurun yang kering atau aspal yang panas mempercepat penguapan (proses adveksi). Peran kedua adalah bertindak untuk mempercepat penguapan dengan menambah *turbolence* transfer uap air dari daerah lembab ke atmosfer kering, dalam kasus ini, angin secara konstan menggantikan udara lembab dengan udara kering dari atas. Semakin besar kecepatan angin, laju penguapan juga semakin besar.

- c. **Kelembaban** menentukan kekeringan atau daya pengering dari atmosfer. Semakin besar kelembaban, maka penguapan akan semakin kecil.
- d. **Temperatur** mempengaruhi VPD (*Vapor Pressure Deficit*) yaitu variabel meteorologi yang biasa digunakan untuk menghitung daya pengeringan dari atmosfer serta mempengaruhi adveksi. Semakin besar temperatur, semakin besar pula jumlah penguapan.

Persamaan di bawah ini menjelaskan hubungan ketika total penguapan (E) diukur secara langsung bersama nilai rata-rata dari kelembaban (q) dan kecepatan angin (U) serta nilai rata-rata dari q dan U pada suatu ketinggian a.

$$E = \rho C_{Ea} (q_s - q_a) U \quad (1)$$

Dimana:

E : total penguapan

q_s : kelembaban spesifik saturasi pada udara

q_a : kelembaban udara pada ketinggian a


C_{Ea} : koefisien pertukaran dari uap air pada ketinggian a

ρ : kepadatan udara

U : kecepatan angin

Pentingnya memahami proses penguapan yang merupakan rangkaian *hydrologic cycle* dan proses presipitasi yang merupakan alur proses terhadap curah hujan yang akan diramalkan.

3. Hujan



Gambar 3. Proses hujan sebagai rangkaian dari *hydrologic cycle* (Brian J. Knap, 1979)

Proses hujan dimulai dengan penguapan air pada permukaan bumi hingga saturasi dan membentuk awan, hingga pada suatu kondisi tertentu konten air pada awan tersebut jatuh dalam bentuk drop air yang dikenal dengan hujan. Secara umum diilustrasikan pada bagan di bawah.



Gambar 4. Bagan proses hujan sederhana (olahan sendiri)

Bagian pembentukan hujan yang penting adalah saat udara menjadi saturasi bersama uap air, kondisi ini disebut kondensasi yang merupakan tahapan pertama dari presipitasi. Kondisi saturasi ini dipengaruhi oleh Kelembaban Relatif (*Relative Humidity*). Kelembaban Relatif (RH) didefinisikan sebagai:

$$RH = \frac{e_a}{e_s} \quad (2)$$

Dimana:

e_a : tekanan uap air aktual (dalam kPa atau mbar)

e_s : tekanan uap saturasi. Udara menjadi saturasi jika RH 100%.

Tekanan uap aktual tergantung dari konsentrasi uap air (atau kepadatan ρ_v) dari paket udara. Variabel ini dihubungkan melalui hukum gas ideal yang diberikan pada persamaan berikut:

$$e_a = \rho_v R_d T \quad (3)$$

Dimana:

ρ_v : kepadatan uap air

R_d : konstanta gas dari udara kering (=287.04 Joules kg⁻¹ K⁻¹)

T : temperatur absolut (K)

0,622 diperoleh dari 18/29 yaitu rasio berat molekul air dan udara. Tekanan uap saturasi didefinisikan sebagai tekanan saat paket udara disaturasikan oleh uap air. Artinya penambahan uap air ke paket udara ini tidak dapat dilakukan tanpa mengubah temperaturnya. Sehingga tekanan uap

saturasi bervariasi tergantung oleh besar temperaturnya, hubungan ini dikenal dengan persamaan *Claussius-Clapeyron*.

$$\left(\frac{e_s}{T} \right) = 0,611 \frac{e_s}{T^2} \quad (4)$$


Dimana:

T_c : temperatur udara (C)

Oleh karena itu, $RH \rightarrow 100\%$, jika:

- 1) ρ_v naik (untuk temperatur yang tetap) atau
- 2) Temperatur turun.

Hubungan antara T_c dan e_s disajikan pada Gambar berikut:



Gambar 5. Variasi eksponensial tekanan uap saturasi dengan temperatur udara (Dawei Han: 2010)

Penurunan temperatur akan menurunkan e_s secara exponential (Gambar 5) yang akan memaksa $e_s = e_a$. Salah satu mekanisme untuk

menurunkan temperatur adalah dengan mengangkat paket udara ke elevasi yang lebih tinggi.

Saat paket udara diangkat ke elevasi yang lebih tinggi, paket udara ini akan menjadi dingin dan menurunkan nilai tekanannya (e_s). Di ketinggian atau elevasi saat $e_s = e_a$ inilah awan akan terbentuk. Istilah *Lifting Condensation Level* (LCL) biasanya digunakan untuk menjelaskan elevasi atau bagian ini.

Umumnya, udara akan dingin pada 10 K per 1000 m. Jumlah ini disebut sebagai *Dry Adiabatic Lapse Rate* (Γ_d), dengan:

$$\Gamma = - \quad (5)$$

Dimana:

g : percepatan gravitasi ($=9.8 \text{ m s}^{-2}$)

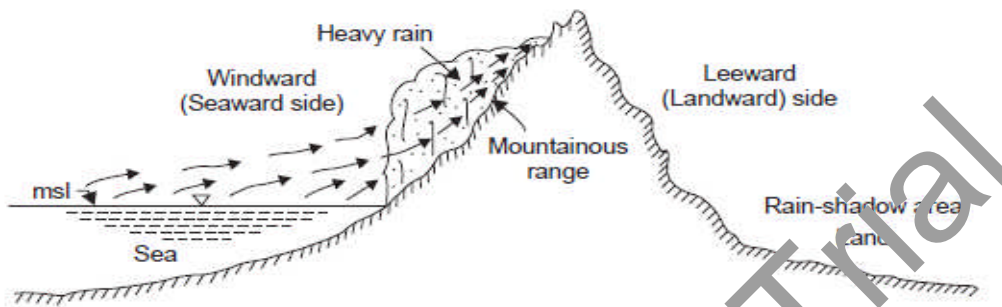
C_p : kapasitas panas spesifik dari udara kering pada tekanan konstan ($=1005 \text{ Joules Kg}^{-1} \text{ K}^{-1}$).

B. Klasifikasi Hujan

Mekanisme dimana udara diangkat merupakan cara yang digunakan untuk mengklasifikasi tipe hujan. Ada 3 mekanisme pengangkatan udara, yaitu:


1. *Orographic Lifting*, yaitu proses dimana udara dipaksa untuk naik ke pegunungan atau tempat yang lebih tinggi. Udara akan mengembang

dan mendingin hingga akhirnya proses presipitasi dalam bentuk hujan pun terjadi. Gambar berikut mengilustrasikan kondisi ini.




Gambar 6. Proses *orographic* presipitasi (Ragunath, 2007)

2. *Frontal Surface Lifting*, yaitu proses saat udara yang lebih panas dipaksa ke atas udara yang lebih dingin pada suatu equilibrium dengan permukaan yang lebih dingin. Proses ini juga dapat diakibatkan oleh pemuatan udara pada pendakian di sepanjang atau dekat permukaan frontal.




Gambar 7. Proses terjadinya frontal surface lifting (Ragunath, 2007)

3. *Convective Lifting* merupakan proses dimana udara panas naik dari permukaan yang panas dan semakin mendingin. Proses ini paling sering terjadi pada daerah tropis. Gambar berikut mengilustrasikan proses ini.




Gambar 8. Proses terjadinya *convective lifting* (Lundquist, 2010)

Ketiga mekanisme ini dapat mengangkat udara dan menghasilkan proses pendinginan yang dibutuhkan untuk mengurangi nilai es dan mendapatkan $RH = 100\%$.



Gambar 9. Perbandingan radius, volume dan kecepatan inti awan dan titik hujan (Elizabeth Shaw, 1994)



Gambar 10. Proses keseluruhan dan parameter yang mempengaruhi hujan (Modifikasi dari Lunquist, 2010)

Setelah uap air mengalami kejenuhan, proses berikutnya dari rangkaian proses hujan adalah terbentuknya titik-titik kecil awan disepanjang inti awan (*Condensation Nuclei*). Inti ini terdapat pada atmosfer dalam orde 0,1 hingga 10 μ m dan terbentuk dari proses pembakaran, nitrogen oksida, aerosol, partikel garam, dan lain sebagainya.

Pada Gambar 9, inti awan memiliki radius 0,1 micrometer sebanyak 106 dalam 1 liter dan kecepatan 0,0001 cm/s, terbentuknya titik awan yang akhirnya semakin membesar akan mengakibatkan bertambahnya radius, volume serta kecepatan terminal (Terminal Velocity). Secara garis besar gambaran mengenai proses presipitasi serta parameter yang mempengaruhinya diilustrasikan pada Gambar 10.

C. Curah Hujan

Curah hujan adalah jumlah air hujan yang turun pada suatu daerah dalam waktu tertentu. Sementara intensitas curah hujan merupakan perbandingan derivasi jumlah hujan terhadap interval waktu tertentu dalam satuan m/s, mm/menit atau inci/jam. Dalam menentukan intensitas atau laju hujan, ada beberapa faktor yang perlu diperhatikan:

1. Durasi hujan dalam detik, menit atau jam;
2. Kedalaman hujan yang dinyatakan sebagai ketipisan lapisan air pada permukaan dalam mm atau inci;
3. Daerah, adalah luas geografis dari curah hujan dalam km²;
4. Frekuensi terjadinya, biasanya dinyatakan sebagai periode kembali, misalnya sekali dalam 10 tahun.

D. Pengukuran Curah Hujan Menggunakan *Rain Gauge*


Rain gauge merupakan salah satu cara untuk mengukur curah hujan yang terjadi pada suatu daerah. *Rain gauge* mengukur volume atau berat hujan yang terkumpul dalam sebuah wadah dengan diameter lubang tetap, ukuran lubang perlu distandarisasikan. Area yang disarankan adalah 200 cm^2 dan tipe dari area lubang adalah $200 - 500 \text{ cm}^2$. *Rain gauge* dibagi menjadi 2 tipe, non-recording dan recording.

1. *Rain Gauge Non Recording*

Tipe *non-recording* meliputi *rain gauge* silinder dan *rain gauge* biasa. Pada tipe ini, pengukuran hujan dilakukan secara manual oleh peneliti.

Gambar berikut adalah sebuah *rain gauge* symon yang memiliki cerobong dengan tepi melingkar berdiameter 12,7 cm dan botol kaca sebagai penerima. Pembungkus logam silindernya tetap dan vertikal ke pondasi batu dengan tinggi 30,5 cm di atas permukaan tanah. Hujan jatuh ke corong yang dikumpulkan oleh penerima dan diukur dalam gelas ukur khusus dalam mm. curah hujan yang ketika penuh dapat mengukur 1,25 cm hujan.

Curah hujan diukur setiap hari dan selama hujan keras harus diukur 3 hingga 4 kali sehari. *Rain gauge* tipe ini hanya memberikan kedalaman total dari curah hujan untuk 24 jam sebelumnya (curah hujan harian) dan tidak dapat memberikan intensitas dan durasi hujan selama interval waktu yang berbeda dalam satu hari.



Gambar 11. *Rain gauge symon* (Ragunath, 2007)

2. *Rain Gauge Recording*


Tipe ini memiliki pengaturan mekanik otomatis yang terdiri dari sebuah jarum jam, sebuah drum dengan sebuah kertas grafik yang tetap dan sebuah ujung pensil yang dapat menggambar kurva massa hujan. Dari kurva ini, kedalaman hujan pada waktu yang ditentukan, intensitas atau laju hujan pada jarak manapun selama badai, waktu permulaan dan penghentian hujan dapat ditentukan.

Tipe ini terbagi atas beberapa model, diantaranya:

a. *Rain gauge tipping bucket*

Terdiri dari penerima silindris berdiameter 30 cm dengan sebuah corong di dalamnya. Di bawah corong, sepasang ember diputar sehingga ketika salah satu ember menerima 0,25 mm hujan akan mengosongkan ke

sebuah tanki di bawahnya, sementara ember lainnya menggantikan posisi ember sebelumnya.




Gambar 12. *Rain gauge tipping bucket* (Ragunath, 2007)

Proses ini terus berulang dari proses *tipping* ini menggerakkan rangkaian listrik yang menyebabkan pensil bergerak pada sebuah chart.

b. Rain gauge tipe weighing


Ketika berat tertentu dari hujan terkumpul dalam sebuah tanki, yang berimpu pada keseimbangan tuas, membuat pensil bergerak pada sebuah chart yang terbungkus mengelilingi drum penggerak. Rotasi drum mengatur skala waktu. Saat gerak vertikal, alat ini merekam hujan kumulatif.



Gambar 13. *Rain gauge tipe weighing* (Ragunath, 2007)


c. *Rain Gauge Tipe Float*

Hujan terkumpul pada suatu ruang mengampung dan bergerak ke t pensil bergerak pada sebuah shart yang terbungkus disekitar drum. Ketika ruang mengampung terisi, air siphon keluar secara otomatis melalui tabung siphon dan disimpan pada ruang siphon yang saling terinterkoneksi. Jarum jam memutari drum sekali dalam 24 jam.



Gambar 14. *Rain gauge tipe float* (Ragunath, 2007)

Gambar berikut menunjukkan kurva massa curah hujan yang merupakan output dari peralatan rain gauge.




Gambar 15. Kurva massa curah hujan (Ragunath, 2007)

E. Pengukuran Curah Hujan Menggunakan Radar dan Satelit

Biasanya daerah terpencil atau daerah yang sulit terjangkau membutuhkan pengukuran curah hujan menggunakan radar atau satelit. Radar bekerja pada dasar pemantulan pulsa energi yang ditransmisikan oleh radar dan diuraikan menjadi peta-peta yang memberikan lokasi (*Plan Position Indicator, PPI*) dan ketinggian (*Range Height Indicator, RHI*).

Sebuah teknologi yang dapat memonitor curah hujan melalui *remote sensing* yaitu satelit. Geostationary Satelit yang diorbitkan pada kecepatan yang sama dengan rotasi bumi dapat menghasilkan sebuah film mengenai

perkembangan cuaca dengan sebuah interval waktu. Resolusi gambar dalam orde 1 km. Hal ini memungkinkan kita untuk memonitor lebih dekat.



Gambar 16. Bentuk display radar. (a) PPI (b) RHI (P.J.M de Laat et.al., 1976)

F. Menentukan Besaran Curah Hujan


Untuk tujuan teknis, biasanya besaran curah hujan rata-rata pada suatu area atau dikenal dengan area curah hujan (*areal rainfall*) dibutuhkan. Ada beberapa metode yang digunakan untuk menentukan besaran curah hujan rata-rata pada suatu area dari pengukuran titik.

1. Metode Kedalaman Rata-rata (*Average Depth Method*).

Nilai *mean* dari jumlah curah hujan terukur pada suatu area menyediakan estimasi yang memuaskan untuk hujan yang relatif seragam. Namun, satu dari metode berikutnya lebih tepat untuk daerah pegunungan atau jika *rain gauge* tidak terdistribusi merata.

2. Metode Thiessen

Garis-garis di gambar untuk menghubungkan stasiun curah hujan, termasuk yang berada di luar area yang akan dianalisis. Garis hubung dibelah tegak lurus untuk membentuk sebuah poligon disekeliling stasiun.




Gambar 17. Metode Thiessen (P.J.M de Laat et.al., 1976)

Untuk menentukan nilai mean jumlah curah hujan dari setiap stasiun dikalikan dengan area dari poligonnya dan jumlah hasil dibagi dengan total area

3. Metode Kriging


DG Kriges seorang ahli pertambangan, mengembangkan metode untuk interpolasi dan merata-ratakan informasi yang bervariasi. Berbeda dengan metode lainnya, metode ini juga mengindikasikan level akurasi dari estimasi yang dibuat.



Gambar 18. Perbandingan Metode Thiessen (a) dan Metode Kriging (P.J.M de Laat et.al., 1976)

4. Metode Isohyetal

Curah hujan yang diamati untuk periode tertentu digambar pada sebuah peta dan kontur dari kedalaman hujan (Isohyets) juga digambar. Area curah hujan ditentukan dengan mengukur area antara isohyets, mengalikannya dengan hujan rata-rata antara isohyets kemudian membagi jumlah hasilnya dengan total area



Gambar 19. Metode Isohyetal (P.J.M de Laat et.al., 1976)

G. Peramalan Curah Hujan

Peramalan merupakan proses dalam memperkirakan suatu nilai untuk kejadian tertentu pada masa depan dengan metode-metode khusus dan pertimbangan segala parameter yang mungkin mempengaruhi. Peramalan dapat juga dikatakan sebagai suatu estimasi tentang hal-hal yang paling mungkin terjadi pada masa yang akan datang berdasarkan eksplorasi dari masa lalu, sehingga diperlukan data masa lalu untuk mengetahui hubungan antar variabel di dalamnya.

Peramalan dapat dilakukan menggunakan metode statistik misalnya menggunakan data *time series* dan data *cross section*, ataupun bisa juga dengan menggunakan metode sederhana seperti *judgement* dari pembuatnya.

Berdasarkan sifatnya, peramalan dibedakan atas dua macam, yaitu:

1. Peramalan Kuantitatif. Peramalan ini didasarkan atas data kuantitatif masa lalu. Hasil peramalannya sangat tergantung pada metode yang digunakan dalam peramalan tersebut.
2. Peramalan Kualitatif. Peramalan yang didasarkan atas data kualitatif pada masa lalu. Hasil peramalan yang dibuat sangat bergantung pada orang yang menyusunnya. Hal ini penting karena hasil peramalan tersebut ditentukan berdasarkan pemikiran yang intuitif, pendapat, pengetahuan dan pengalaman penyusunnya.

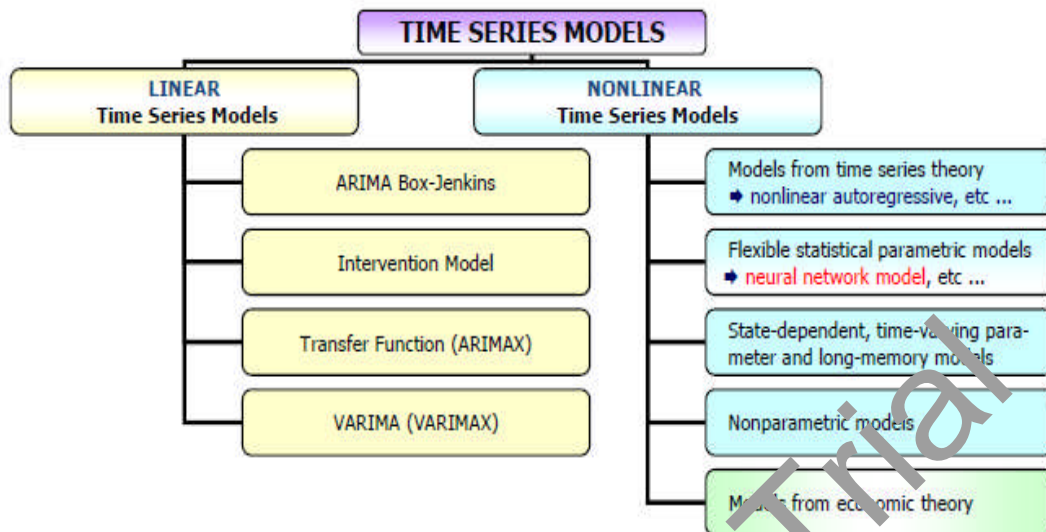
Parameter baik tidaknya suatu metode didasarkan oleh perbedaan atau penyimpangan antara hasil ramalan dengan kenyataan yang terjadi. Semakin kecil penyimpangan antara hasil ramalan dengan kenyataan yang terjadi, maka semakin baik pula metode yang digunakan. Peramalan kuantitatif dapat diterapkan bila terdapat kondisi sebagai berikut:

1. Tersedia informasi (data) tentang masa lalu
2. Informasi (data) tersebut dapat dikuantitatifkan dalam bentuk data numerik
3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut pada masa yang akan datang.

Kegunaan metode ini adalah untuk memperkirakan secara sistematis dan pragmatis atas dasar data yang telah ada pada masa lalu, dengan demikian metode peramalan diharapkan dapat memberikan objektivitas yang lebih besar.

1. *Time-Series*

Terdapat banyak model dalam *forecasting*. Salah satu yang paling populer adalah *time series forecasting*. *Time series* adalah sekumpulan data yang diukur berdasarkan waktu yang berturutan dengan pencacahan waktu yang sama. Analisa *time series forecasting* bertujuan untuk memprediksi data di masa depan berdasarkan data-data di masa lalu.



Gambar 20. Klasifikasi Metode Time Series (Tino Parasvirta, et, al., 2010)

Dalam *time series forecasting*, data historis dari variabel-variabel yang digunakan untuk memprediksi terlebih dahulu dikumpulkan dan dianalisa untuk membentuk model yang dapat menggambarkan hubungan-hubungan di antara observasi yang berbeda waktu. Model yang didapat kemudian digunakan untuk memodelkan pergerakan data di masa depan.

Time series forecasting dapat dikelompokkan menjadi 3 golongan, sebagai berikut:

- a. *Subjective: forecast* yang dibuat berdasarkan *judgement*, intuisi, dan pengetahuan sebelumnya.
- b. *Univariate* (regresi sederhana): mem-*forecast* nilai di masa depan hanya berdasarkan satu tipe dari nilai-nilai di masa lalu. Contohnya adalah: ekstrapolasi kurva *trend*, *exponential smoothing*.

- c. *Multivariate* (regresi *multivariate*): mem-forecast berdasarkan nilai dari satu atau lebih variabel. Contohnya adalah: model *multiple* regresi linear, dan model-model ekonometri.

Dalam peramalan curah hujan, metode yang umum digunakan adalah:

- a. Metode Regresi
- b. Metode ARIMA dan ASTAR
- c. Metode Kecerdasan Buatan (Jaringan Saraf Tiruan)

Peramalan curah hujan selain digunakan untuk mengetahui kondisi hujan ke depan untuk waktu tertentu, juga digunakan untuk *monitoring* iklim, deteksi kekeringan, cuaca buruk (badai, dll), peringatan dan peramalan banjir serta *monitoring* dan pengontrolan Daerah Aliran Sungai (DAS).

Beberapa peneliti yang akan meramalkan ataupun *monitoring* banjir menggunakan data curah hujan dengan terlebih dahulu melakukan peramalan hujan. Watanabe, *et.al.* (2009) melakukan peramalan ketinggian air pada Sungai Sabu dan Sungai Onga, Jepang dengan menggunakan data curah hujan. Rizyanti, *et.al.* (2011) melakukan peramalan curah hujan dan menggunakan hasil peramalannya sebagai masukan sebuah sistem yang berbasis SCADA yang merupakan solusi untuk pencegahan banjir.

Berdasarkan kebutuhan dan pengolahan, data curah hujan dikategorikan menjadi:

- a. Curah hujan harian
- b. Curah hujan bulanan
- c. Curah hujan tahunan

2. Analisis Regresi

Istilah regresi pertama kali diperkenalkan oleh Francis Galton (1886). Analisis ini berkenaan dengan studi ketergantungan dari suatu variabel yang disebut variabel tak bebas, pada satu atau lebih variabel, yaitu variabel yang menerangkan dengan tujuan untuk memperkirakan ataupun meramalkan nilai-nilai dari variabel tak bebas apabila nilai variabel yang menerangkan sudah diketahui. Variabel yang menerangkan sering disebut variabel bebas.

Metode ini terbagi menjadi dua, yaitu metode regresi linear sederhana dan metode regresi linear berganda.

3. ARIMA (*Auto Regressive Integrated Moving Average*)

Tidak seperti model regresi, yang mana Y_t dapat dijelaskan oleh k buah regressor $X_1, X_2, X_3, \dots, X_k$, model ARIMA memungkinkan Y_t dijelaskan oleh nilai Y sendiri di mana lalu ditambah dengan *stochastic error* terlm (Gujarati, 2003, p. 867).

Model ARIMA dapat dibentuk dari dua buah model, yakni model AR(p) (*Auto Regressive*) dan model MA(q) (*Moving Average*). Model AR berbentuk hubungan antara variabel dependen Y dengan variabel dependen Y waktu sebelumnya.

Model MA menunjukkan hubungan variabel dependen Y terhadap nilai-nilai residual pada waktu sebelumnya secara berturutan. P menunjukkan orde autoregressive, dan q menunjukkan notasi orde dari moving average. Proses AR dan MA dapat dimodelkan sebagai berikut:

$$\begin{aligned} (Y_t - \mu) &= (Y_t - \mu) + (Y_t - \mu) + \dots + (Y_t - \mu) - \mu + \mu \\ &= \mu + \mu + \mu + \mu + \dots + \mu \end{aligned} \quad (6)$$

$$= \mu + \mu - \mu + \mu \quad (7)$$

Persamaan (6) disebut model AR, persamaan (7) disebut model MA. Gabungan keduanya disebut model ARMA. Contoh model ARIMA dapat dilihat pada persamaan (10).

Rumus AR dan MA di atas mengasumsikan bahwa data mengikuti proses yang stasioner. Jika data tidak stasioner, maka perlu melakukan *differencing*, menghasilkan ARIMA (p, d, q), dimana menunjukkan orde differencing sampai didapat data yang stasioner. Model ARIMA (p, d, q) dapat dinyatakan dalam:

$$\phi(B)Y_t = \mu + \epsilon_t \quad (8)$$

$$\phi(B) = 1 - \phi_1(B) - \phi_2(B) - \dots - \phi_p(B) \quad (9)$$

$$\theta(B) = 1 - \theta_1(B) - \dots - \theta_q(B) \quad (10)$$

Model ARIMA (p, d, q) tersebut merupakan univariate ARIMA, yang berarti variabel dependen Y hanya dipengaruhi oleh pergerakan variabel dependen Y pada waktu sebelumnya. Penelitian ini menggunakan multivariate ARIMA, dikarenakan variabel dependen Y (harga saham masa depan) juga dipengaruhi oleh banyak variabel independen (Xi) waktu sebelumnya. Model multivariate ARIMA dapat dituliskan sebagai berikut:

$$= (X_t) \quad (11)$$

$$\Delta = + \sum \text{---} \Delta () + \text{---} \quad (12)$$

Dimana:

$$= (\text{---} \text{---} \text{---} \text{---}) *$$

$$(1 - \Omega \text{---} \text{---} \text{---}) \quad (13)$$

$$= (1 - \text{---} \text{---} \text{---}) (1 - \text{---} \text{---}) \quad (14)$$

Persamaan di atas merupakan persamaan untuk multivariate ARIMA.

4. ANN (*Artificial Neural Network*)

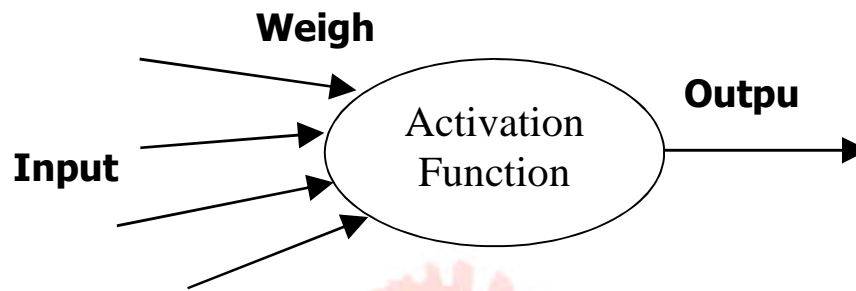
Meskipun model multivariate ARIMA cukup fleksibel dalam memodelkan sebagian besar pola *time series*, kekurangannya adalah bahwa ARIMA mengasumsikan model yang linier. Hal ini menyebabkan model ARIMA tidak dapat menangkap pola-pola yang non-linier yang umum terdapat pada *time series*. Oleh karena itu, perlu dibuat suatu model yang dapat menangkap pola-pola yang non-linier. Model tersebut adalah model ANN (*Artificial Neural Network*).

Menurut Gershenson (2003) cara yang efisien untuk memecahkan problem yang kompleks adalah memecahkan permasalahan tersebut ke dalam elemen-elemen yang lebih kecil (*divide and conquer*). Model ANN dapat melakukan kegiatan semacam ini.

Model ANN diinspirasi dari sistem saraf makhluk hidup. Saraf menerima sinyal melalui sinapsis yang terletak di *dendrit* atau membran *neuron* adalah

satu sel saraf. Ketika sinyal yang disampaikan cukup kuat (melampaui suatu batas/*threshold* tertentu), *neuron* akan diaktivasi dan akan mentransmisikan sinyal melalui *akson*, dan dapat mengaktivasi *neuron* yang lain. Ketika sejumlah besar *neuron* memproses sinyal dalam waktu bersamaan, maka makhluk hidup dapat memecahkan suatu masalah tertentu yang kompleks. Untuk memecahkan permasalahan yang belum pernah dijumpai dalam hidupnya, makhluk hidup perlu belajar dari pengalaman-pengalamannya di masa lalu, untuk kemudian memutuskan solusi yang tepat.

Konsep yang sama dimodelkan oleh konsep jaringan saraf tiruan (*Artificial Neural Network*) menggunakan program komputer. Ketika sejumlah besar *artificial neuron* memproses data secara bersamaan, maka permasalahan baik ekonomi, bisnis, ataupun permasalahan sehari-hari yang kompleks dapat dipecahkan dengan mudah. Sama seperti saraf makhluk hidup, *artificial neuron* perlu mendapatkan *training*/pelatihan untuk memecahkan permasalahan yang belum pernah ditemui. Memecahkan masalah-masalah yang belum diketahui ini adalah konsep *forecasting*, dimana *artificial neuron* dilatih menggunakan data-data di masa lalu, untuk kemudian dipakai untuk memecahkan masalah-masalah di masa depan yang belum pernah diketahui sebelumnya. Sejumlah besar *artificial neuron* disebut juga *artificial neural network*. Konsep *artificial neuron* yang menjadi dasar ANN dapat digambarkan seperti Gambar 21 berikut ini:




Gambar 21. Konsep artificial neuron (Gershenson, 2003)

Pada dasarnya, *artificial neuron* terdiri dari input (seperti sinapsis), yang kemudian dimultiplikasi oleh *weights* (kekuatan sinyal) dan kemudian dihitung oleh fungsi matematik yang dilambangkan dengan fungsi aktivasi. Jika hasil perhitungan melampaui batas tertentu, maka hasil perhitungan akan ditransmisikan melalui output ke *neuron* yang lain.

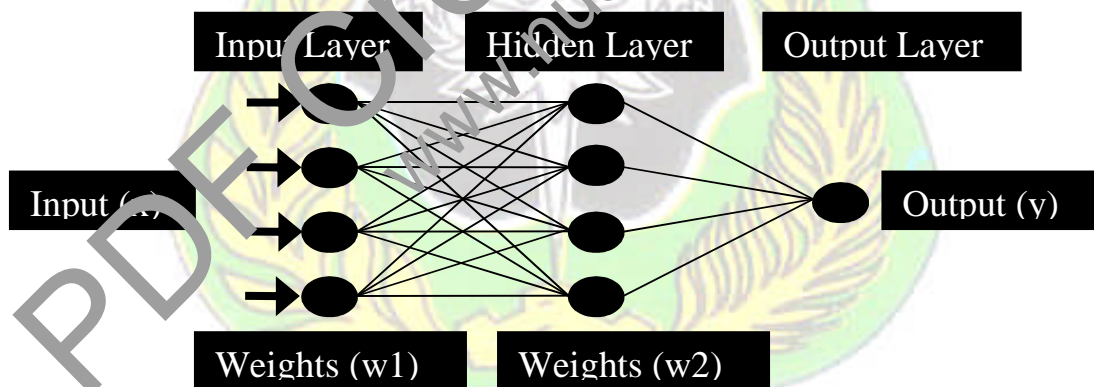
Semakin besar *weights*, maka semakin kuat sinyal input yang dimasukkan ke dalam *neuron*. Dengan mengatur besarnya *weights*, kita bisa mendapatkan output yang diinginkan dengan menggunakan input tertentu. Jika terdapat ratusan atau ribuan *neuron*, sulit menemukan perhitungan yang tepat jika menggunakan perhitungan manual. Oleh karena itu digunakan algoritma yang secara otomatis melakukan perhitungan *weights* ini agar didapat *weights* yang dapat memetakan input menjadi output yang sesuai. Proses perubahan *weights* secara otomatis inilah yang disebut pelatihan/training pada *artificial neural network*.

Gambar 21 memperlihatkan proses perubahan *weights* yang membandingkan antara input dengan target, sehingga didapatkan *weights* yang sesuai.



Gambar 22. Proses pelatihan ANN (Demuth, 2009)

Pada Gambar 22 terdapat abstraksi dari *neural network* yang pada dasarnya dapat memiliki susunan *artificial neuron* seperti pada Gambar 23 berikut:



Gambar 23. Detail ANN (Zhang, 2004a)

Pada Gambar 23 terlihat ANN selain mempunyai *neuron*, *weights*, input, dan output, ANN juga mempunyai *hidden layer*. *Hidden layer* berada

di antara input dan output. *Hidden layer* dapat terdiri dari satu atau lebih *neuron*. Model ANN bisa mempunyai satu atau lebih *hidden layer*.

5. *Hidden Layer* dan Neuron

Hidden layer berpengaruh terhadap kemampuan model ANN untuk menggeneralisasi/aproksimasi suatu fungsi/pola. Penelitian yang dilakukan oleh Iskandar (2010) menghasilkan informasi bahwa cukup diperlukan satu atau dua *hidden layer* saja untuk fungsi aproksimasi ini.

Jumlah *neuron* yang optimal pada *Hidden layer* berpengaruh terhadap keakuratan model ANN dalam mem-forecast suatu deret data. Jika jumlah *neuron* terlalu banyak, maka model cenderung akan tidak mampu menggeneralisasi (menjadi *overfitting*). Ini berarti model hanya berfungsi baik hanya di ruang sampelnya saja, dan apabila di-test menggunakan data yang di luar sampel, maka model ANN akan tidak dapat memprediksi dengan baik. Jika jumlah *neuron* terlalu sedikit, maka yang terjadi adalah model akan tidak dapat memprediksi dengan baik meskipun di-test menggunakan data yang berada di dalam sampel.

6. *Algoritma Back Propagation*

Pada *algoritma back propagation*, vektor input dan vektor target digunakan untuk melatih ANN sampai ANN dapat mengaproksimasi sebuah deret data. Error selisih yang terjadi antara target dengan data yang sebenarnya, dipropagasikan/ditransmisikan kembali ke dalam *network* melalui

hidden layer menuju ke *neuron* input. *Weights* kemudian akan dihitung kembali dan masing-masing *neuron* akan mentransmisikan kembali sinyal ke *hidden layer* dan *neuron* output untuk kemudian akan dihitung kembali *error*/selisih antara target dengan data sebenarnya. Proses ini diulang terus menerus sampai *error* yang terjadi berada dalam *range* yang ditentukan di awal.

Menurut Siang (2005), algoritma back propagation meliputi tiga fase. Fase pertama adalah fase maju. Pola input dihitung maju mulai dari input *layer* hingga output *layer* menggunakan fungsi aktivasi yang ditentukan. Fungsi aktivasi akan dibahas di sub bab berikutnya. Fase kedua adalah fase mundur. Selisih antara output dengan target adalah *error* yang terjadi. *Error* tersebut dipropagasikan mundur, mulai dari output *layer*, *hidden layer*, sampai ke input *layer*. Fase ketiga adalah modifikasi *weights* untuk menurunkan *error* yang terjadi.

7. Fungsi Aktivasi

Fungsi aktivasi digunakan untuk menentukan keluaran/output suatu *neuron*. Parameter fungsi aktivasi adalah kombinasi linier antara input dan *weights*. Dalam *back propagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat, yaitu kontinyu, terdiferensial dengan mudah, dan merupakan fungsi yang tidak turun.


Menurut Buwana (2006), fungsi aktivasi pada ANN digunakan untuk memformulasikan output dari setiap *neuron*. Pada ANN, terdapat tiga jenis fungsi aktivasi, yakni fungsi aktivasi *sigmoid logistic*, *sigmoid tangent*, dan

fungsi aktivasi linier. Fungsi aktivasi *sigmoid logistic* memetakan nilai input antara 0 dan +1. Nilai yang ditransmisikan/diaktivasi ke *neuron* lain berada pada jangkauan 0 dan +1. Grafik fungsi *sigmoid logistic* dapat dilihat pada



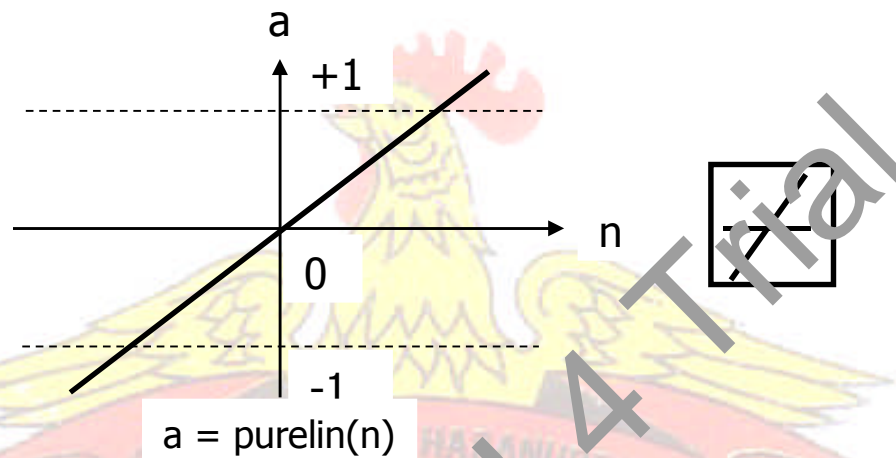
Gambar 24. Fungsi aktivasi sigmoid logistic (Demuth, 2009)

Fungsi aktivasi *sigmoid tangent* memetakan nilai input antara +1 dan -1. Nilai yang ditransmisikan/diaktivasi ke *neuron* lain berada pada jangkauan +1 dan -1. Grafik fungsi aktivasi *sigmoid tangent* dapat dilihat pada Gambar 25.



Gambar 25. Fungsi aktivasi sigmoid tangent (Demuth, 2009)

Fungsi aktivasi linier meneruskan nilai input ke *neuron* lain dengan tanpa perubahan nilai aktivasi. Grafik fungsi aktivasi linier dapat dilihat pada Gambar 26.



Gambar 26. Fungsi aktivasi linier (Demuih, 2009)

8. *Preprocessing* dan *Postprocessing*

Pelatihan/training pada ANN dapat lebih efisien jika data input dan data target dilakukan pemrosesan terlebih dahulu. Jika data input tidak dilakukan pemrosesan/ditransformasikan, ANN tidak dapat menghasilkan output yang akurat (Mendelsohn, 2007). Data input ditransformasikan ke dalam bentuk yang lebih sederhana melalui proses *preprocessing*. Setelah data diproses oleh ANN, outputnya dikembalikan kembali ke bentuk data semula melalui proses *postprocessing*.

Proses *preprocessing* dan *postprocessing* yang dilakukan dalam penelitian ini menggunakan transformasi minimum-maksimum, sehingga setiap data input ditransformasikan menjadi dalam *range* -1 sampai dengan +1. Menurut Iskandar (2010), pemetaan seperti inilah yang berdampak

maksimum terhadap keakuratan hasil *forecast* model ANN. Algoritma minumum-maksimum adalah sebagai berikut:

$$= \frac{(- \quad - \quad) * (- \quad - \quad)}{(- \quad - \quad)} + \quad - \quad \quad (15)$$

Y adalah nilai diantara -1 dan +1. $y_{max} = +1$, $y_{min} = -1$, dan x_{max} serta x_{min} bergantung pada nilai maksimum dan minimum data inputnya. Proses transformasi balik ke data awal dilakukan dengan mengkurakan invers dari persamaan di atas dengan mencari variabel X.

9. Training Pada *Back Propagation*

Algoritma *Back Propagation* mempunyai bermacam-macam jenis training. Macam-macam training tersebut diantaranya:

a. *Gradient descent Back Propagation*

Pada jenis training ini, *weights* dari ANN di-update berdasarkan *gradient* negatif dari fungsi perubahan *error*-nya.

b. *Gradient descent Back Propagation with momentum*

Metode ini sama dengan *gradient descent*, hanya saja ditambahkan momentum yang memungkinkan ANN merespon tidak hanya kepada local *gradient error*-nya, tetapi juga *trend* yang baru saja terjadi pada perubahan *error*-nya.

c. *Conjugate gradient Back Propagation with Powell-Beale restarts*

Conjugate gradient mencari arah penurunan yang paling curam dari *gradient* penurunan *error*-nya. Terdapat cara yang lebih efisien untuk

meningkatkan efisiensi training, yaitu dengan menerapkan *reset functions*. *Algoritma* ini melakukan *reset* jika ditemui ortogonalitas yang kecil di antara *gradient error* saat ini dengan *gradient iterasi* sebelumnya.

d. *Scaled conjugate gradient Back Propagation*

Setiap *algoritma* yang telah disebutkan sebelumnya memerlukan proses pencarian *gradient error* terkecil pada tiap iterasi pelatihannya. Ini memerlukan waktu yang cukup lama, terlebih jika ANNs yang dilatih mempunyai ukuran yang besar. *Algoritma scaled conjugate gradient* dapat meminimalkan waktu pencarian tersebut, dimana mengkombinasikan pendekatan *trust-region* seperti yang dilakukan oleh *Algoritma Levenberg-Marquardt*.

e. *BFGS quasi-newton Back Propagation*

Algoritma ini merupakan alternatif dari *algoritma conjugate gradient*. *Algoritma* ini konvergen lebih cepat daripada *algoritma conjugate gradient*, akan tetapi perhitungannya lebih rumit dan membutuhkan kapasitas memori yang besar.

f. *Levenberg-Marquardt Back Propagation*

Seperti halnya metode *quasi-newton*, *algoritma* ini didesain untuk meningkatkan kinerja training, tanpa perlu melakukan perhitungan turunan kedua dari perubahan *error*-nya. *Algoritma* ini menggunakan pendekatan (aproksimasi) untuk menghitung turunan kedua perubahan *error*-nya.

g. *Batch training with weight and bias learning rules*

Algoritma ini melatih ANN menggunakan *weight learning rules* dengan *update* secara *batch*. *Weights* di-*update* pada akhir setiap iterasi pelatihan ANN.

h. Bayesian regulation Back Propagation

Algoritma training ini melakukan *update weights* sesuai dengan cara yang dilakukan oleh proses optimisasi *Levenberg-Marquardt*. *Algoritma* ini meminimalisasi kombinasi *squared error* dan *weights* lalu kemudian menentukan kombinasinya yang sesuai untuk menghasilkan ANN yang dapat menggeneralisasi dengan baik.

i. Gradient descent with adaptive learning rate Back Propagation

Algoritma ini melakukan *update pada weight* sesuai dengan metode *gradient descent* dengan *adaptive learning rate*. Pada setiap iterasi *training*, jika *gradient error* menurun ke arah *target error*, maka laju pembelajaran (*learning rate*) ditingkatkan. Jika *gradient error* tidak menurun ke arah *target error*, maka laju pembelajaran (*learning rate*) tidak akan berubah.

j. Gradient descent with momentum and adaptive learning rate Back Propagation

Algoritma ini melakukan *update pada weight* sesuai dengan metode *gradient descent* dengan *adaptive learning rate* dikombinasikan dengan momentum.

k. One-step secant Back Propagation

Algoritma BFGS diatas membutuhkan perhitungan yang rumit dan kapasitas memori yang besar dibandingkan *algoritma conjugate gradient*. *Algoritma* ini menggunakan pendekatan (*aproksimasi*) secant sehingga perhitungan rumit tersebut bisa lebih cepat dan tidak membutuhkan banyak kapasitas memori. *Algoritma* ini tidak menyimpan seluruh matriks turunan kedua perubahan *errormya* dengan mengasumsikan matriks turunan kedua pada iterasi sebelumnya adalah matriks identitas. Keuntungannya adalah tidak diperlukan perhitungan matriks invers dalam penentuan *gradient errormya*.

l. Resilient Back Propagation

Algoritma ini merupakan *algoritma back propagation* yang mana perubahan membesar/mengecilnya *weights* ditentukan oleh perubahan tanda (*sign*) dari turunan pertama perubahan *error-nya*.

m. Sequential order incremental training with learning functions

Algoritma ini men-*update* nilai tiap *weights* mengacu kepada fungsi pembelajaran/*learning* berdasarkan urutan waktu dan urutan data input.

H. Variabel Data untuk Peramalan Curah Hujan

Seperti yang telah diuraikan pada bagian sebelumnya, parameter penentu curah hujan merupakan variabel penting dalam peramalan curah hujan yang akan dijelaskan pada bagian berikutnya.

1. Intensitas Sinar Matahari

Intensitas sinar matahari adalah banyaknya sinar matahari yang mengenai suatu permukaan tertentu dalam suatu waktu. Parameter ini yang paling mempengaruhi proses penguapan yang merupakan awal terjadinya hujan.

Besarnya intensitas sinar matahari sangat dipengaruhi oleh posisi daerah pada permukaan bumi, semakin mendekati khatulistiwa maka intensitas matahari yang diterima juga semakin besar, sehingga dapat dikatakan semakin besar posisi garis lintang maka intensitas sinar matahari juga semakin kecil.

Radiasi sinar matahari memiliki energi panas yang besar dan sangat mempengaruhi proses penguapan. Proses penguapan ini merupakan proses awal dari terbentuknya hujan. Banyak penelitian yang menghubungkan antara intensitas sinar matahari atau radiasi sinar matahari dengan curah hujan pada suatu tempat.

D. Medvgy, et al. (2012) menyelidiki variasi radiasi sinar matahari dan variasi hujan sejak tahun 1984 hingga 2002, dan menyimpulkan bahwa kenaikan variasi radiasi matahari ini berhubungan dengan naiknya variasi hujan. Sementara *Juan Zhao, et al (2004)* melakukan pengujian hubungan antara aktivitas matahari dengan curah hujan tahunan di Beijing, China dan memperoleh hasil adanya hubungan yang erat antara intensitas matahari dengan curah hujan tahunan. *Guo et.al. (1992)* berkesimpulan bahwa banjir besar (peningkatan curah hujan) akan terjadi pada tahun-tahun dimana aktifitas matahari meningkat, karena meningkatnya energi dari matahari akan menyebabkan tingginya fungsi *thermo-mechanical* atmosfer bumi. *Pederson et*

al. (2001) menemukan bukti adanya pengaruh matahari terhadap curah hujan tahunan dan rekonstruksi *hidro-meteorologi* lainnya di *Northeastern Mongolia* yang berasal dari lingkaran pohon dari tahun 1651 – 1995.

Penelitian empiris mengenai hubungan intensitas/radiasi sinar matahari terhadap curah hujan telah membuktikan kaitannya, kenaikan intensitas sinar matahari akan menyebabkan kenaikan curah hujan pada suatu daerah.

2. Temperatur

Temperatur adalah keadaan panas atau dinginnya udara. Alat untuk mengukur suhu udara atau derajat panas disebut thermometer. Pengukuran dinyatakan dalam skala Celsius (C), Reamur (R), dan Fahrenheit (F). Suhu udara tertinggi di muka bumi adalah di daerah tropis (sekitar ekuator) dan makin ke kutub makin dingin.

Faktor-faktor yang mempengaruhi tinggi rendahnya suhu udara suatu daerah adalah:

- a. Lama penyinaran matahari, makin lama matahari bersinar, semakin banyak panas yang diterima bumi.
- b. Sudut datang sinar matahari, yaitu sudut yang dibentuk oleh permukaan bumi dengan arah datangnya sinar matahari. Makin kecil sudut sinar matahari, semakin sedikit panas yang diterima oleh bumi dibandingkan sudut yang datangnya tegak lurus.
- c. Keadaan permukaan bumi (daratan dan lautan).

- d. Banyak sedikitnya awan, ketebalan awan mempengaruhi panas yang diterima bumi. Makin banyak atau makin tebal awan, semakin sedikit panas yang diterima bumi.

Persebaran suhu atau temperatur udara dapat dibedakan menjadi dua, yaitu persebaran horizontal dan vertikal yakni:

- a. Persebaran suhu atau temperatur udara horizontal.

Suhu atau temperatur udara di permukaan bumi untuk berbagai tempat tidak sama. Untuk mempermudah membandingkannya, maka dibuat peta *isotherm*. *Isotherm* yaitu garis khayal dalam peta yang menghubungkan tempat-tempat yang mempunyai suhu atau temperatur udara rata-rata sama. Persebaran horizontal secara tidak teratur dipengaruhi oleh kondisi lingkungannya.

- b. Persebaran suhu atau temperatur udara vertikal

Semakin naik suhu atau temperatur udara akan semakin turun. Secara umum, setiap naik 100 meter, suhu atau temperatur udara turun $0,5^{\circ}\text{C}$. Ketentuan ini tergantung pada letak dan ketinggian suatu tempat. Adanya perairan, seperti selat dan laut sangat besar perannya pada mengendalikan suhu atau temperatur, sehingga tidak terjadi perbedaan suhu terendah dan suhu tertinggi yang sangat besar.

Hubungan antara temperatur dengan curah hujan telah banyak diteliti, *Bulshard. T.A, et.al.* (1999) melakukan penelitian mengenai ketergantungan presipitasi terhadap temperatur di *Florence* dan *Livorno*, Italia dan menghasilkan suatu kesimpulan bahwa kenaikan temperatur akan

mengakibatkan penurunan durasi hujan. Korelasi negatif antara hujan dan temperatur permukaan juga ditemukan pada penelitian *Trenberth, et.al* (2005) dan beberapa penelitian lainnya.

Banyak penelitian mengacu pada persamaan *Clausius-Clapeyron* (Pers. II.4) yang telah dijelaskan pada bagian awal, bahwa temperatur mempengaruhi tekanan uap saturasi, yaitu tekanan saat pake udara disaturasikan oleh uap air (proses kondensasi). Kenaikan temperatur menyebabkan penurunan tekanan uap saturasi yang mengakibatkan melambatnya proses kondensasi dan akhirnya menurunkan curah hujan.

3. Kelembaban Udara

Di udara terdapat uap air yang berasal dari penguapan samudera (sumber yang utama). Sumber lainnya berasal dari danau-danau, sungai-sungai, tumbuh-tumbuhan, dan sebagainya. Kelembaban udara (*Humidity*) adalah banyaknya kandungan uap air di atmosfer. Ada dua macam kelembaban udara:

- a. Kelembaban udara absolut, ialah banyaknya uap air yang terdapat di udara pada suatu tempat. Dinyatakan dengan banyaknya gram uap air dalam 1 m³ udara.
- b. Kelembaban udara relatif, ialah perbandingan jumlah uap air dalam udara (kelembaban absolut) dengan jumlah uap air maksimum yang dapat dikandung oleh udara tersebut dalam suhu yang sama dan dinyatakan dalam persen (%).

Dalam proses hujan, kondisi saturasi antara udara dan uap air juga dipengaruhi oleh kelembaban relatif (*Relative Humidity*). Kenaikan kelembaban ini mengakibatkan kenaikan pada curah hujan. Penelitian Jones, *et.al* (2010) menunjukkan hubungan antara presipitasi, temperatur dan kelembaban relatif dan hasilnya mengindikasikan kelembaban menjadi salah satu penggerak dominan terjadinya presipitasi ekstrim.

4. Tekanan Udara

Kepadatan udara tidak sepadat tanah dan air. Namun udarapun mempunyai berat dan tekanan. Besar atau kecilnya tekanan udara, dapat diukur dengan menggunakan barometer. Orang pertama yang mengukur tekanan udara adalah *Torri Celli* (1643). Alat yang digunakannya adalah barometer raksa. Tekanan udara menunjukkan tenaga yang bekerja untuk menggerakkan massa udara setiap satuan luas tertentu. Tekanan udara semakin rendah apabila semakin tinggi dari permukaan laut. Satuan dalam ukuran tekanan udara adalah milibar. $1 \text{ mb} = 1 \text{ mm tekanan ar raksa (t.a.r)}$ atau $1013 \text{ mb} = 76 \text{ cm t.a.r} = 1 \text{ atmosfer}$

Garis pada peta yang menghubungkan tempat-tempat yang sama tekanan udaranya disebut isobar. Bidang isobar ialah bidang yang tiap-tiap titiknya mempunyai tekanan udara sama. Jadi perbedaan suhu akan menyebabkan perbedaan tekanan udara. Daerah yang banyak menerima panas matahari, udaranya akan mengembang dan naik. Karena itu, daerah tersebut bertekanan udara rendah.

Hubungan antara curah hujan dan tekanan merupakan hubungan yang berbanding terbalik. Ketika tekanan udara rendah maka curah hujan lebih banyak terjadi dan ketika tekanan yang lebih tinggi maka sedikit hujan turun. Ketika ada tekanan rendah di atmosfer, maka gelembung udara yang naik selalu lebih panas dari udara disekitar. Udara panas akan naik secara bertahap dan ketika naik, udara panas ini akan dingin namun tidak akan secepat udara sekitarnya. Dengan demikian udara ini akan tetap lebih panas dari udara sekitar dan akan terus naik. Tekanan rendah akan menyebabkan kondisi udara tidak stabil. Jika tanah dipanaskan maka udara akan naik. Udara dingin akan menghasilkan kondensasi yang pada akhirnya akan mengarah pada hujan.

Sebaliknya, jika kondisi di atmosfer berada pada tekanan tinggi, maka gelembung udara yang naik selalu lebih dingin dibandingkan udara di sekitar. Udara panas tidak akan terus naik dan akan mendingin. Dengan demikian akan dingin lebih cepat daripada udara disekitar. Tekanan tinggi menyebabkan kondisi udara yang stabil. Jika tanah dipanaskan maka udara tidak akan naik sehingga uap air tidak dapat berkondensasi.

Hubungan tekanan dan hujan yang diteliti *Speer, et.al* (2012) mendapatkan hasil bahwa tekanan pada wilayah yang terletak pada Selatan Inggris mendominasi pola curah hujan. *Speer* juga menemukan hubungan tekanan-hujan merupakan hubungan yang sangat konsisten selama multi-dekade, musiman, bulanan dan harian skala waktu serta menunjukkan bahwa curah hujan Mediterania adalah fenomena kuat yang dipengaruhi oleh perubahan skala besar tekanan. Studi Solot di Hawaii menunjukkan korelasi

antara hujan terhadap anomasi tekanan tertentu di belahan bumi utara (*Riehl*, 1954)

5. Angin

Angin adalah udara yang bergerak. Ada tiga hal penting yang menyangkut sifat angin yaitu:

a. Kekuatan Angin

Menurut hukum *Stevenson*, kekuatan angin berbanding lurus dengan *gradient barometriknya*. *Gradient barometrik* ialah angka yang menunjukkan perbedaan tekanan udara dari dua isobar pada tiap jarak 15 meridian (111 km).

b. Arah Angin

Satuan yang digunakan untuk besaran arah angin disebut derajat ($^{\circ}$). Satu derajat untuk arah angin dari utara, 90 derajat untuk arah angin dari timur, 180 derajat untuk arah angin dari selatan dan 270 derajat untuk arah angin dari barat. Arah angin menunjukkan dari mana datangnya angin dan bukan ke mana angin itu bergerak. Menurut hukum *Buys Ballot*, udara bergerak dari daerah yang bertekanan tinggi (maksimum) ke daerah bertekanan rendah (minimum), di belahan bumi utara berbelok ke kanan sedangkan di belahan bumi selatan berbelok ke kiri. Arah angin dipengaruhi oleh tiga faktor yaitu: *gradien barometrik*, rotasi bumi, dan kekuatan yang menahan (rintangan).

Makin besar *gradient barometrik*, makin besar pula kekuatannya. Angin yang besar kekuatannya makin sulit berbelok arah. Rotasi bumi, dengan bentuk bumi yang bulat, menyebabkan pembelokan arah angin. Pembelokan angin di ekuator sama dengan 0 (nol). Makin ke arah kutub pembelokannya makin besar. Pembelokan angin yang mencapai 90° sehingga sejajar dengan garis isobar disebut *angin geotropik*. Hal ini banyak terjadi di daerah beriklim sedang di atas samudera. Kekuatan yang menahan dapat membelokkan arah angin. Sebagai contoh, pada saat melalui gunung, angin akan berbelok ke arah kiri, ke kanan atau ke atas.

c. Kecepatan angin

Atmosfer ikut berotasi dengan bumi, molekul-molekul udara mempunyai kecepatan gerak ke arah timur, sesuai dengan arah rotasi bumi. Kecepatan gerak tersebut disebut kecepatan linier. Bentuk bumi yang bulat ini menyebabkan kecepatan linier makin kecil jika makin dekat ke arah kutub. Alat untuk mengukur kecepatan angin diukur dengan menggunakan *anemometer*.

Kecepatan Angin erat kaitannya dengan penguapan seperti yang telah dijelaskan pada bagian Penguapan dan hubungan ini lebih jelas teridentifikasi pada persamaan (1). Semakin besar kecepatan angin maka laju penguapan juga semakin besar sehingga memperbesar curah hujan.

Raymond et.al. (2003) memaparkan dalam penelitiannya bahwa semakin tinggi kecepatan angin maka akan semakin banyak penguapan dan semakin banyak fluks panas latent dari lautan ke atmosfer. Kenaikan angin permukaan rata-rata pada suatu daerah dan periode akan

meningkatkan curah hujan seiring dengan peningkatan fluks panas latent tersebut.

Back et.al (2005) melakukan kajian serupa, yaitu meneliti hubungan antara kecepatan angin dan curah hujan pada daerah Pasifik dan mendapatkan hubungan yang sangat kuat di antara keduanya. Semakin besar kecepatan angin, maka semakin besar pula curah hujan yang terjadi.

6. Curah Hujan

Curah hujan merupakan jumlah air hujan yang turun pada suatu daerah dalam waktu tertentu. Curah hujan diukur dalam harian, bulanan, dan tahunan. Hujan merupakan unsur iklim yang paling penting di Indonesia karena keseragamannya sangat tinggi baik menurut waktu maupun tempat, sehingga kajian tentang iklim lebih baik diarahkan pada hujan. Hujan adalah salah satu bentuk dari presipitasi, presipitasi adalah sebuah proses jatuhnya butiran air atau kristal es ke permukaan bumi. Jumlah curah hujan dicatat dalam inci atau milimeter (1 inci = 25,4 mm). Curah hujan sebesar 1 mm artinya adalah tinggi air hujan yang terukur setinggi 1 mm pada daerah seluas 1 m². Tinggi curah hujan diasumsikan sama disekitar tempat penakaran, luasan yang tercakup oleh sebuah penakaran curah hujan tergantung pada homogenitas daerahnya maupun kondisi cuaca lainnya.

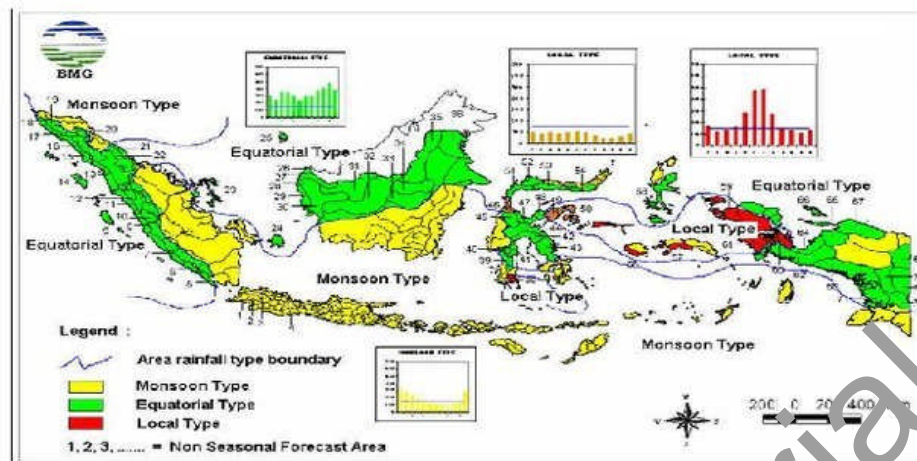
Definisi hujan menurut standar *internasional World Meteorological Organization* (WMO) adalah sebagai berikut:

Tabel 2. Klasifikasi curah hujan menurut standar internasional (WMO)

Kriteria Hujan	Intensitas Hujan
Sangat Ringan	< 5.0 mm
Ringan	5.0 – 20 mm
Sedang/Normal	20 – 50 mm
Lebat	50 – 100 mm
Sangat Lebat	> 100 mm

Pola curah hujan di wilayah Indonesia tidak sama. Hal tersebut karena perbedaan letak geografis. Secara klimatologis pola hujan di Indonesia dapat dibagi menjadi tiga pola yaitu:

- Pola moonson, dicirikan bentuk unimodal yakni terdapat perbedaan yang jelas antara periode musim hujan dan periode musim kemarau.
- Pola hujan equatorial, yang wilayahnya memiliki distribusi hujan bulanan bimodal (dua puncak musim hujan) yang biasanya terjadi di bulan Maret dan Oktober yaitu pada saat matahari berada dekat ekuator.
- Pola hujan lokal, dicirikan oleh bentuk pola hujan unimodal (satu puncak hujan) yang wilayahnya memiliki distribusi hujan bulanan tetapi bentuknya berlawanan dengan pola moonson.




Sumber: Pola curah hujan 2008, BMG

Gambar 27. Wilayah Indonesia berdasarkan pola hujan (Istriana, 2009)

Data curah hujan masa lalu merupakan salah satu variabel yang penting untuk melakukan peramalan curah hujan, variabel ini bersama kelima variabel lainnya (intensitas matahari, temperatur udara, kelembaban relatif, tekanan udara dan kecepatan angin) merupakan parameter input pada metode peramalan hujan yang akan digunakan, dalam hal ini metode *Artificial Neural Network*, dengan demikian akan diperoleh hasil peramalan curah hujan harian yang akurat.

I. Kerangka Pikir Penelitian



Gambar 28. Kerangka pikir penelitian

BAB III

METODE PENELITIAN

A. Pengumpulan Data

1. Jenis data

Data yang akan digunakan adalah data observasi harian dari enam variabel cuaca di Kota Makassar. Data ini didapatkan melalui BMKG Wilayah IV Makassar. Stasiun pengamatan yang diambil adalah Makassar Hasanuddin yang terletak di kompleks Bandara Sultan Hasanuddin dengan periode data yaitu dari tahun 2001-2010. Data iklim yang digunakan untuk memprediksi curah hujan merupakan data dari Kota Makassar dengan area ZOM 287 yang memiliki karakteristik hujan tertentu. Sehingga perhitungan untuk memprediksi curah hujan tersebut hanya dapat digunakan di area ZOM 287. Pembagian daerah di Sulawesi berdasarkan nomor ZOM dapat dilihat pada lampiran 2.

Dari data harian meteorologi BMKG dengan periode 2001-2010, ditemukan beberapa data yang kosong. Khususnya pada periode tahun 2001-2003 yang disebabkan oleh perekaman data konvensional. Untuk itu *data preprocessing* menjadi hal yang krusial agar sistem ini dapat mencapai keakurasian yang diinginkan.

Selain itu pemilihan-pemilihan data serta pengklasifikasiannya ke dalam waktu periode tertentu juga menjadi hal penting untuk mencapai sistem prediksi yang akurat. Akan diperlukan proses *normalisasi* serta *differencing*

untuk mengarahkan data menjadi *stasioner*, sekaligus juga diharapkan mampu mengatasi permasalahan data *missing* di periode-periode awal.


Jika data periode 2001-2003 memberikan kontribusi negatif kepada hasil prediksi, maka dimungkinkan untuk mengeliminasi periode tersebut dari proses pelatihan sistem. Validasi sistem selanjutnya akan menggunakan radar milik Teknik Lingkungan Sipil dan LAPAN yang berada di kampus Unhas Tamalanrea. Hal ini memudahkan proses validasi selanjutnya karena akses dan validasi dari data akan menjadi lebih mudah dan akurat.

Radar LAPAN selama setahun ini telah disetting dengan resolusi sampling yang lebih tinggi yaitu pengambilan data setiap 10 menit. Berbeda dengan data BMKG yang disampling setiap 2 jam yang mana dari kumpulan data ini kemudian di rata-ratakan sebagai angka harian untuk diarsipkan. Meskipun demikian, data dari LAPAN belum representatif untuk digunakan karena jumlah data yang diperoleh belum cukup banyak. Selain itu dalam proses instalasi banyak terdapat tahapan kalibrasi ulang serta *system malfunction* sehingga secara praktis 4 bulan awal pengambilan data dinyatakan invalid. Oleh sebab itu dalam penelitian ini tetap menggunakan data dari BMKG sebagai data primer. Hal ini jugalah yang dapat menjadi penjelasan dari kurang maksimalnya sistem prediksi yang ingin dicapai.

Kota Makassar termasuk dalam Region atau daerah A yang pola curah hujannya berbentuk huruf U atau dikenal sebagai Pola Hujan Monsoon. Daerah A ini memiliki perbedaan yang jelas antara periode musim hujan dan periode musim kemarau kemudian dikelompokkan dalam Zona Musim (ZOM)

dan memiliki tipe curah hujan yang bersifat unimodial (satu puncak musim hujan, Des-Jan-Feb musim hujan, Jun-Jul-Agt musim kemarau).

Gambar di bawah ini memperlihatkan data curah hujan Kota Makassar yang diperoleh dari BMKG. Data ini merupakan salah satu data latih untuk memprediksi yang berupa grafik rata-rata curah hujan di Kota Makassar dan nantinya akan digunakan untuk memprediksi curah hujan tahun 2009 dan 2010. Tampak bahwa model kurva berbentuk U dengan puncak di bulan Februari (musim hujan) tetapi lembah di bulan Juli-September yang artinya terjadi sedikit pergeseran waktu untuk musim kemarau (Juni-Agustus).



Gambar 29. Grafik curah hujan rata-rata Kota Makassar tahun 2004-2009

2. Teknik Pengambilan Data

Data yang akan dikumpulkan didasarkan pada variabel yang mempengaruhi curah hujan, antara lain:

- a. Curah hujan sebelumnya (mm/hr)
- b. Temperatur udara ($^{\circ}\text{C}$)
- c. Intensitas penyinaran matahari (%)
- d. Tekanan udara (mBar)
- e. Kelembaban nisbi (%)
- f. Kecepatan dan arah angin (knot)

Data dari berbagai variabel tersebut diperoleh dengan menggunakan instrumentasi terkait variabel pengambilan data yang telah tersedia di dalam dan luar ruang observasi di BMKG. Beberapa instrumentasi tersebut antara lain:

- a. *Thermometer*

Secara umum, *thermometer* berfungsi sebagai alat pengukur suhu.



Gambar 30. Termometer

b. Thermograph

Berfungsi untuk mengukur suhu dan kelembaban udara secara otomatis. Dengan menggunakan pias kertas sebagai hasil yang dilihat, kemudian di bagian kertas tersebut terdapat pengukur suhu (bagian atas kertas) dan pengukur kelembaban (bagian bawah kertas). Dengan menggunakan sensor, maka grafik perubahan suhu bisa diketahui, karena sensor tersebut sangat peka terhadap suhu sekitar dimana mengalami pemuaian bila suhu meningkat dan menyusut jika suhu rendah.

c. Barometer


Secara umum barometer berfungsi untuk mengukur tekanan udara.



Gambar 31. Barometer

d. *Barograph*

Berfungsi sebagai pengukur tekanan udara secara otomatis tercatat di kertas.



Gambar 32. Barograph

e. Anemograph

Berfungsi sebagai alat pengukur kecepatan dan arah angin.



Gambar 33. Anemograph

f. Anemometer dan Penunjuk Arah Angin

Untuk mengukur kecepatan angin.



Gambar 34. Anemometer dan penunjuk arah angin

g. *Campbell Stokes*


Untuk mencatat lama penyinaran matahari.



Gambar 35. *Campbell stokes*

h. Penakar Hujan

Untuk mengukur curah hujan



Gambar 36. Penakar hujan (a) tipe Ob. (b) tipe Hillman

3. Metode Analisis

Data dari tiap variabel akan dianalisis dengan 2 cara yaitu:

a. Uji Korelasi

Data meteorology yang tersedia di BMKG sebelumnya dilakukan uji korelasi yang mana data tersebut terdiri atas 6 variabel dengan variasi beberapa *lagging*. Hal ini ditujukan untuk memperoleh hasil prediksi yang lebih baik serta waktu pemrosesan yang lebih singkat. Beberapa step yang akan dilakukan untuk menentukan korelasi linier antara 2 variabel unsur meteorology antara lain:

- Menentukan sampel yang representatif
- Menentukan persamaan regresi dari kedua variabel tersebut.
- Melakukan Uji linieritas regresi

- Jika hasil regresi linier maka dilanjutkan dengan menghitung r .
- Uji p kemudian kategorikan dalam koefisien korelasi untuk melihat tingkat korelasinya.

Jika unsur meteorology yang diuji memiliki korelasi kecil, maka sangat dimungkinkan unsur tersebut akan dieleminasi dari pelatihan. Karena data dari BMKG hanya menyediakan sampling harian, maka korelasi diuji dengan *lagging* -1 , 0 dan $+1$ hari. Dari semua parameter diatas akan diuji terlebih dahulu korelasinya terhadap prediksi curah hujan. Dari penelitian (Sanjaya dkk, 2009) hanya menggunakan satu parameter saja yaitu curah hujan sebelumnya. Hasil yang diperoleh juga dalam bentuk kuantitatif yaitu curah hujan prediksi (mm/hr). Penelitian yang dilakukan akan menguji metode untuk menentukan teknik penelusuran terbaik baik secara kuantitatif maupun kualitatif dari semua model prediksi.

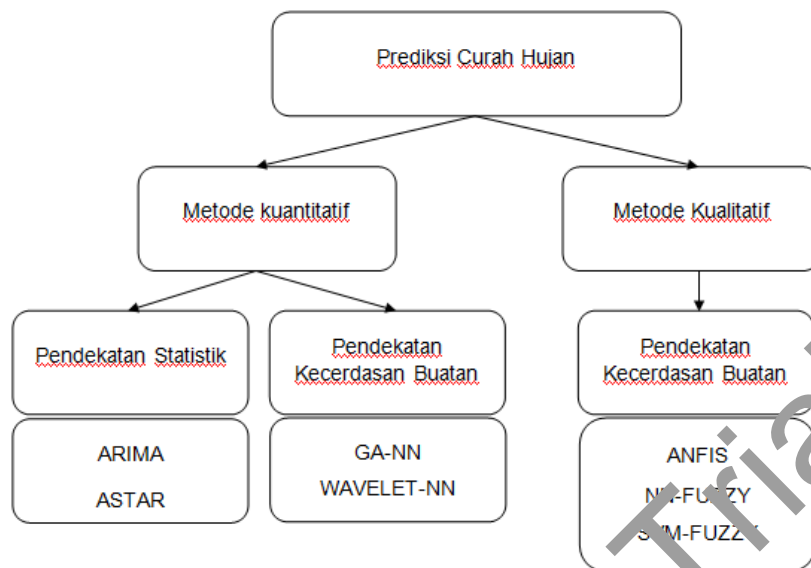
b. Analisis *trend*

Analisis Kecenderungan (tren) berdasarkan time series data variabel rata-rata, maksimum dan minimum serta maksimum dan minimum absolut tahunan. Analisis tren tersebut berdasarkan time series data yang nantinya akan dibandingkan dengan tren jumlah curah hujan harian selang periode 2004-2010 untuk membuktikan korelasi terbaik.

B. Metodologi

Penelitian yang dilakukan akan menghasilkan kebaruan khususnya di kota Makassar berkenaan dengan obyek, parameter maupun teknik peramalan yang potensial untuk digunakan. Dalam penelitian ini **akan diuji beberapa dari model eksisting** dengan data parameter dari BMKG Makassar. **Selain itu sebagai kebaruan dari penelitian yang akan diusulkan adalah pengujian potensi kombinasi dari Support Vector Machine dan Fuzzy Logic untuk menghasilkan prediksi dengan angka kualitatif.**

Skenarionya adalah menggabungkan 2 model prediksi, dimana Fasa 1 untuk memprediksi parameter meteorology harian yang mana hasil ini selanjutnya di proses pada fasa 2 untuk memprediksi curah hujan dalam nilai kualitatif. Dari semua penelitian yang telah dibahas pada bab II, semuanya berorientasi kepada hasil prediksi kuantitatif. Dalam usulan penelitian ini, outcome yang diinginkan adalah angka kualitatif yang dapat digunakan untuk kepentingan untuk pengambilan keputusan seperti pada daerah aliran sungai, penentuan buka tutup bendungan dan lain-lain.

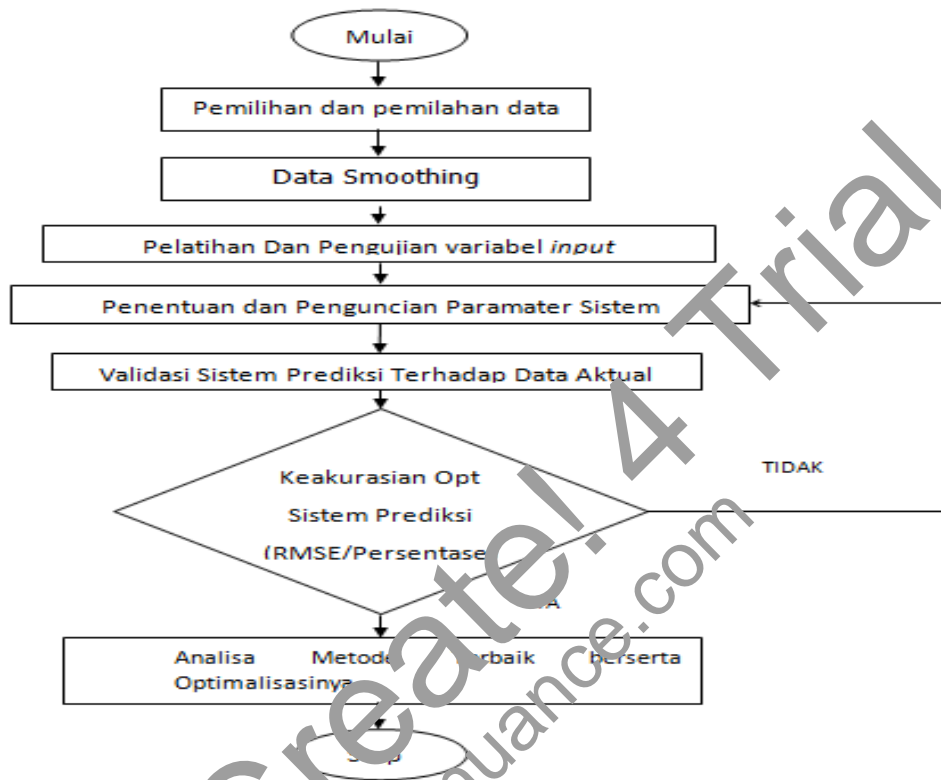


Gambar 37. Metode yang digunakan dalam penelitian

Pada penelitian sebelumnya menunjukkan HyBMC memiliki unjuk kerja terbaik dari 3 model prediksi lainnya. Telah dibahas juga bahwa JST (layer 2) adalah model kecerdasan buatan yang cukup baik dalam menghadapi data tidak stasioner. Dan teknik Fuzzy cukup baik untuk mentransformasikan dan memetakan angka kuantitatif ke kualitatif.

Berdasarkan *preliminary result* dari penelitian awal yang telah dilakukan menggunakan JST dengan data BMKG Makassar (Indrabayu, 2011), sistem JST yang dibangun mengalami kesulitan prediksi karena ekstrimnya perbedaan data pada tahun 2010 terhadap data tahun-tahun sebelumnya. Pada tahun 2010 kota Makassar sangat dipengaruhi oleh ENSO sehingga hampir sepanjang tahun mengalami hujan. Idenya adalah variasi data ini dapat dilakukan *smoothing* dengan menggunakan *wavelet* atau SVM. Dimana data masukan terlebih dahulu dilakukan transformasi *wavelet/svm* sebelum menjadi masukan di JST/GA. Kesulitan pada pembuatan sistem adalah

bagaimana mengkombinasikan ketiga metode ini yang berbeda secara karakteristik.



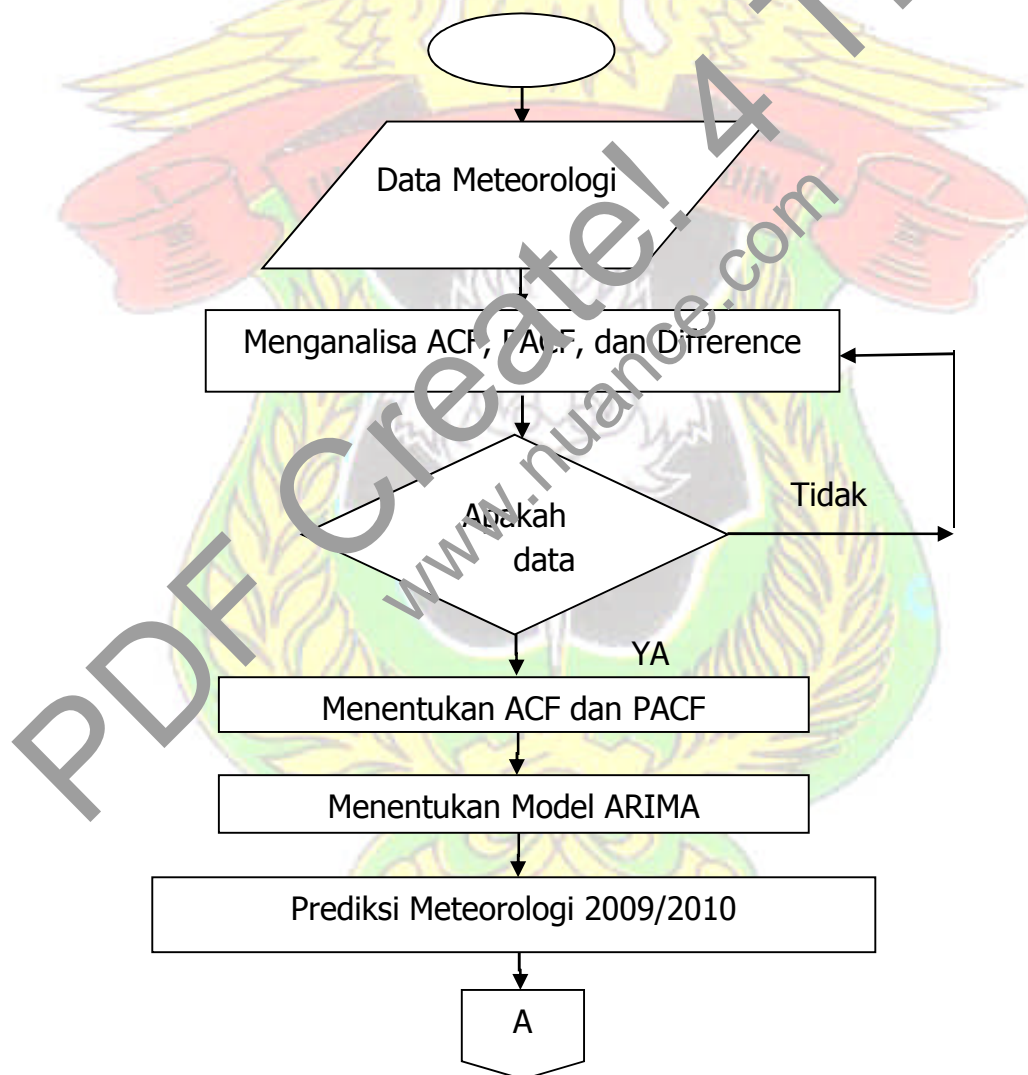
Gambar 39. Langkah-langkah penelitian secara umum

C. ARIMA (Autoregressive Integrated Moving Average)

Metode ARIMA dapat digunakan untuk memprediksi curah hujan dengan pendekatan statistik. Metode ini menjelaskan perancangan sistem prediksi dengan analisis regresi berganda yang digunakan untuk memprediksi cuaca keesokan harinya. Adapun alur ARIMA dapat dilihat pada gambar 39.

1. Metode ARIMA

Teknik analisis data dengan metode ARIMA dilakukan karena merupakan teknik untuk mencari pola yang paling cocok dari sekelompok data (*curve fitting*), dengan demikian ARIMA memanfaatkan sepenuhnya data masa lalu dan sekarang untuk melakukan peramalan jangka pendek yang akurat.



Gambar 39. *Flowchart* prediksi dengan metode ARIMA

ARIMA seringkali ditulis sebagai ARIMA (p, d, q) yang memiliki arti bahwa p adalah *orde koefisien autokorelasi*, d adalah *orde/jumlah diferensiasi* yang dilakukan (hanya digunakan apabila data bersifat non-stasioner) dan q adalah *orde dalam koefisien rata-rata bergerak (moving average)*.

Peramalan dengan menggunakan model ARIMA dapat dilakukan dengan rumus:

$$Y_t = \gamma_0 + \partial_1 Y_{t-1} + \partial_2 Y_{t-2} + \dots + \partial_n Y_{t-p} - \lambda_1 e_{t-1} - \lambda_2 e_{t-2} - \dots - \lambda_n e_{t-p} \quad (16)$$

Keterangan:

- B : Koefisien Regresi
 Y_T : Variabel dependen pada waktu t
 $Y_{t-1} \dots Y_{t-p}$: Variabel lag
 e_t : Residual term
 $e_{t-1} \dots e_{t-p}$: nilai sebelum, va atau residual

2. Stasioneritas Data

Data yang tidak stasioner memiliki rata-rata dan varian yang tidak konstan sepanjang waktu. Dengan kata lain, secara ekstrim data stasioner adalah data yang tidak mengalami kenaikan dan penurunan. Selanjutnya regresi yang menggunakan data yang tidak stasioner biasanya mengarah kepada regresi lancung. Permasalahan ini muncul diakibatkan oleh variabel (dependen dan independen) runtun waktu terdapat tren yang kuat (dengan pergerakan yang menurun maupun meningkat). Adanya tren akan

menghasilkan nilai R^2 yang tinggi, tetapi keterkaitan antar variabel akan rendah.

Model ARIMA mengasumsikan bahwa data masukan harus stasioner. Apabila data masukan tidak stasioner perlu dilakukan penyesuaian untuk menghasilkan data yang stasioner. Salah satu cara yang umum dipakai adalah metode pembedaan (*differencing*). Metode ini dilakukan dengan cara mengurangi nilai data pada suatu periode dengan nilai data periode sebelumnya.

3. Tahapan Metode ARIMA

Metode ARIMA menggunakan pendekatan iterative berfungsi dalam mengidentifikasi suatu model yang paling tepat dari berbagai model yang ada. Model sementara yang telah dipilih diuji lagi dengan data historis untuk melihat apakah model sementara yang terbentuk tersebut sudah memadai atau belum. Model sudah dianggap memadai apabila residual (selisih hasil peramalan dengan data historis) terdistribusi secara acak, kecil dan independen satu sama lain. Langkah-langkah penerapan metode ARIMA secara berturut-turut adalah identifikasi model, estimasi parameter model, *diagnostic checking*, dan peramalan (*forecasting*).

a. Identifikasi model

Seperti yang dijelaskan sebelumnya bahwa model ARIMA hanya dapat diterapkan untuk deret waktu yang stasioner. Oleh karena itu, pertama kali yang harus dilakukan adalah menyelidiki apakah data yang digunakan sudah

stasioner atau belum. Jika data tidak stasioner, yang perlu dilakukan adalah memeriksa pada pembedaan beberapa data akan stasioner, yaitu menentukan berapa nilai d . Proses ini dapat dilakukan dengan menggunakan koefisien ACF (*Auto Correlation Function*), atau uji akar-akar unit (*unit roots test*) dan derajat integrasi. Jika data sudah stasioner sehingga tidak dilakukan pembedaan terhadap data runtun waktu maka d diberi nilai 0.

Disamping menentukan d , pada tahap ini juga ditentukan berapa jumlah nilai lag residual (q) dan nilai lag dependen (p) yang digunakan dalam model. Alat utama yang digunakan untuk mengidentifikasi q dan p adalah ACF dan PACF (*Partial Auto Correlation Funtion / Koefisien Autokorelasi Parsial*), dan correlogram yang menunjukkan plot nilai ACF dan PACF terhadap lag.

b. Estimasi

Setelah menetapkan model sementara dari hasil identifikasi, yaitu menentukan nilai p , q , dan d langkah berikutnya adalah melakukan estimasi parameter *autoregressive* dan *moving average* yang tercakup dalam model. Jika teridentifikasi proses AR murni maka parameter dapat diestimasi dengan menggunakan kuadrat terkecil (*Least Square*). Jika sebuah pola MA diidentifikasi maka *maximum likelihood* atau estimasi kuadrat terkecil, keduanya membutuhkan metode optimisasi non-linier, hal ini terjadi karena adanya unsur *moving average* yang menyebabkan ketidak linieran parameter.

c. *Diagnostic Checking*

Setelah melakukan estimasi dan mendapatkan penduga parameter, agar model sementara dapat digunakan untuk peramalan, perlu dilakukan uji

kelayakan terhadap model tersebut. Tahap ini disebut *diagnostic checking*, dimana pada tahap ini diuji apakah spesifikasi model sudah benar atau belum.

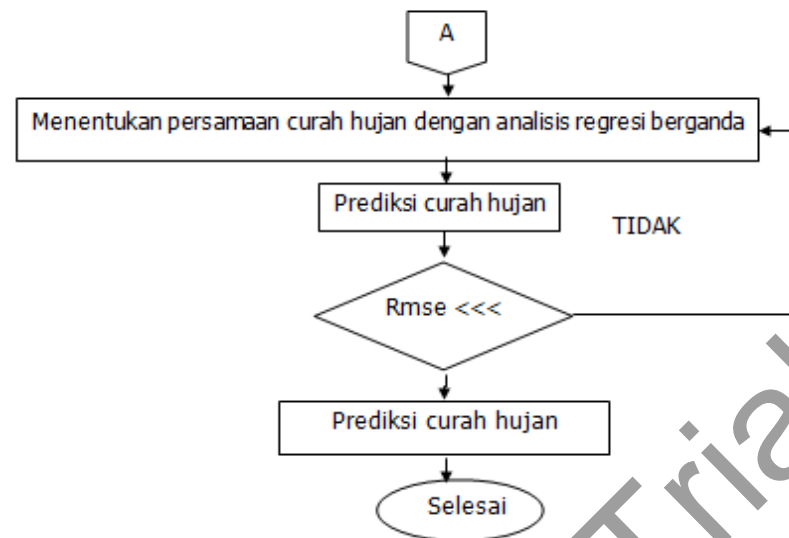
d. Peramalan (*forecasting*)

Setelah model terbaik diperoleh, selanjutnya peramalan dapat dilakukan. Dalam berbagai kasus, peramalan dengan metode ini lebih dipercaya daripada peramalan yang dilakukan dengan model ekonometrik tradisional. Namun, hal ini tentu saja perlu dipelajari lebih lanjut oleh para peneliti yang tertarik menggunakan metode serupa.

Berdasarkan ciri yang dimilikinya, model runtun waktu seperti ini lebih cocok untuk peramalan dengan jangkauan sangat pendek, sementara model struktural lebih cocok untuk peramalan dengan jangkauan panjang.

4. Menentukan Hubungan Parameter Meteorologi Terhadap Curah Hujan dengan Analisis Regresi Berganda

Untuk menentukan hubungan variable meteorologi terpilih terhadap curah hujan, digunakan analisis regresi berganda. Regresi Berganda adalah bagian dari analisis *multivariate*.



Gambar 40. Flowchart dengan analisis regresi berganda

Tujuan utama analisis regresi berganda adalah untuk menduga besarnya koefisien regresi. Selanjutnya, koefisien regresi inilah yang akan menunjukkan besarnya pengaruh peubah bebas (independent variable/X) terhadap peubah tak bebas (dependent variable/Y).

Besarnya pengaruh peubah bebas (independent variable/X) terhadap peubah tak bebas (dependent variable/Y), dengan persamaan:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 \dots + \beta_n X_n + \epsilon_i \quad (17)$$

Dimana:

- Y : Variabel Respon
- X₁ : Variabel bebas parameter 1
- X₂ : Variabel bebas parameter 2
- X_n : Variabel bebas parameter n
- β : Koefisien regresi

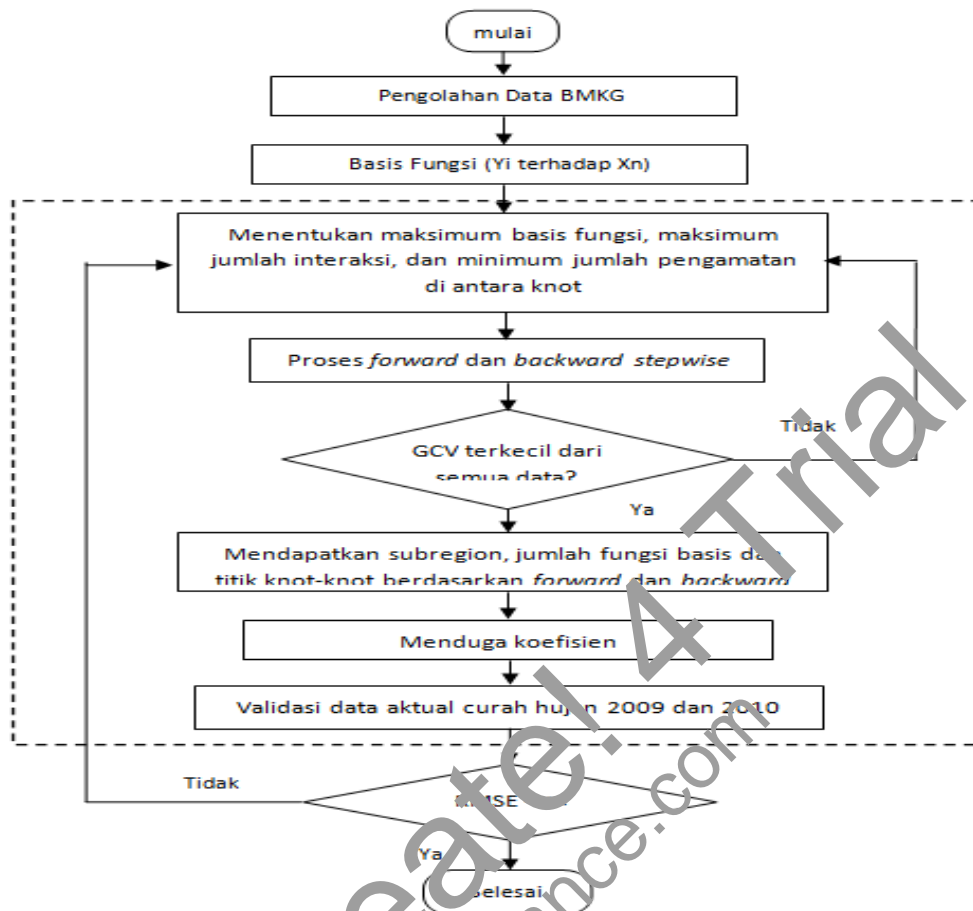
D. ASTAR (*Adaptive Splines Threshold Autoregression*)

1. Prediksi Curah Hujan Dengan Metode Astar

Proses prediksi bertujuan untuk menentukan hasil akhir berupa curah hujan dan nantinya akan dibandingkan dengan data aktual curah hujan dari BMKG. Proses tersebut dinilai baik apabila memiliki nilai error yang sangat kecil dan dilanjutkan untuk memprediksi pada tahun berikutnya.

Model hasil prediksi curah hujan dengan metode ASTAR ini dilakukan dalam bentuk nilai kuantitatif yaitu hasil prediksinya berupa numerik. Model ini dihitung secara manual melalui *software Microsoft Excel* berdasarkan model hujan (Y) terbaik yang diperoleh dari uji linier basis fungsi tiap harinya.

Proses prediksi dengan metode ASTAR dapat dilihat pada gambar 41. Sumber data aktual BMKG dari tahun 2004-2008 di input kedalam *software SPSS 16* untuk mendapatkan variabel prediktor, kemudian inputan tersebut dimasukkan pada *software MARS 2.0* untuk menentukan basis fungsi, titik knot, nilai *Generalized Cross Validation (GCV)*, dan koefisien-koefisien model ASTAR lainnya yang mendukung.



Gambar 4.1. *Flow chart* prediksi curah hujan metode ASTAR

2. Basis Fungsi

Satu basis fungsi adalah jarak antar knot yang berurutan. Dalam ASTAR, basis fungsi adalah satu set fungsi yang menggambarkan informasi yang terdiri dari satu atau lebih peubah. Basis Fungsi menggambarkan hal-hal yang memberikan kontribusi paling besar dalam hubungan peubah respon dan peubah prediktor.

Pada model MARS dilakukan uji signifikansi basis fungsi yang meliputi uji serentak dan uji individu. Uji signifikansi yang dilakukan secara bersamaan

terhadap basis fungsi-basis fungsi yang terdapat dalam model MARS ini yang bertujuan untuk mengetahui model MARS yang terpilih dan menunjukkan hubungan yang tepat antara variabel prediktor dengan variabel respon.

Teknik analisis data dengan metode ASTAR dilakukan untuk mencari model yang terbaik yang paling cocok dari sekelompok data. Dengan demikian ASTAR memanfaatkan sepenuhnya data masa lalu dan sekarang untuk melakukan peramalan jangka pendek yang akurat.

Tahapan Penyusunan model ASTAR:

- Menentukan maksimum basis fungsi, maksimum jumlah interaksi, dan minimum jumlah pengamatan atau observasi diantara knot. Nilai basis fungsi maksimum adalah 2 – 4 kali jumlah variabel prediktor.
- Proses *forward stepwise* untuk mendapatkan jumlah basis fungsi maksimum dengan kriteria pemilihan basis fungsi. Proses ini menggunakan program MARS 2.0.
- Proses *backward stepwise* untuk mendapatkan jumlah basis fungsi yang dihasilkan dari *forward stepwise* dengan meminimumkan nilai *Generalized Cross Validation* (GCV) yang terkecil.
- Melakukan pemilihan titik-titik knot-knot. Pemilihan knot-knot menggunakan *algoritma forward* dan *backward*. Dimana titik knot tersebut merupakan titik dimana terjadi perubahan fungsi secara signifikan dan titik yang mewakili semua banyaknya data.
- Menduga koefisien dari basis fungsi telah terpilih, yang merupakan tahap prediksi variabel respon (Y) terhadap variabel prediktor (X).

Kelinieran dalam peubah prediktor adalah masalah pokok dalam pemodelan. Salah satu strategi pada MARS untuk mengatasi masalah ini dengan mengurangi secara langsung peubah yang akan dimasukkan ke dalam model. Hal ini akan mengurangi interaksi palsu yang diakibatkan oleh kolinieritas dan akan membuat pendugaan yang lebih stabil. Pengurangan peubah dapat disempurnakan dengan menambahkan nilai finalti pada *lack of fit* dalam pemilihan knot yang dilakukan di algoritma tahap maju.

3. Verifikasi dan Validasi Model

Verifikasi model digunakan untuk mengetahui kemampuan model dalam menjelaskan keragaman data dan validasi model untuk melihat kehandalan model tersebut dalam peramalan. Verifikasi model dilakukan dengan menggunakan analisis korelasi, sedangkan validasi model menggunakan RMSE (*Root Mean Square Error*) dan MAE (*Mean Absolute Error*). Tetapi pada penelitian ini menggunakan RMSE untuk membandingkan keakuratan prediksi curah hujan karena melihat system prediksi lainnya, dimana RMSE adalah sebuah estimator nilai yang diharapkan dari kuadrat *error*. *Error* yang ada menunjukkan seberapa besar perbedaan hasil aktual dengan nilai prediksi, sedangkan MAE adalah rata-rata *absolute* dari kesalahan normal tanpa menghitung tanda positif atau negatif.

E. GENETIC ALGORITHM-NEURAL NETWORK (GA-NN)

Langkah-langkah penelitian dengan metode GA-NN selengkapnya digambarkan pada gambar 42.

1. Pelatihan Dan Pengujian Jaringan Untuk Prediksi Variabel Input Dengan *Backpropagation*

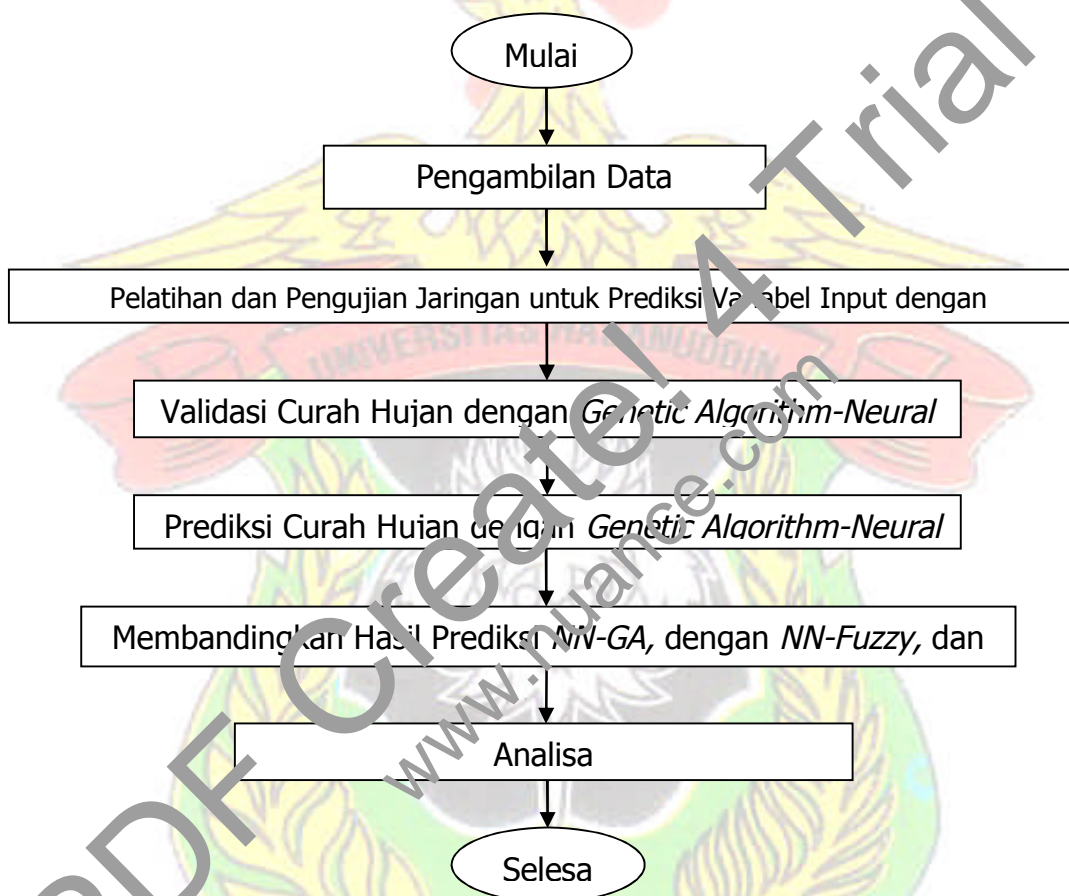
Pelatihan pada metode *Neural Network-Backpropagation* bertujuan agar jaringan bisa mengenali input yang diberikan sesuai target yang diinginkan. Proses pelatihan ini dilakukan berulang kali hingga mendapatkan *error* terkecil atau hingga batas iterasi yang ditentukan. Hasil yang didapatkan dari proses pelatihan akan digunakan untuk proses pengujian. Pengujian jaringan bertujuan untuk melihat apakah persentase kesalahan jaringan dalam memprediksi variabel input sudah kecil, baik itu data latih maupun data uji.

Langkah-langkah dalam proses pelatihan *Neural Network Back Propagation* adalah sebagai berikut:

- a. Memuat data setiap variabel input dari tahun 2004-2009, dimana data training (data input) merupakan data tahun 2004-2008 dan data target merupakan data tahun 2009.
- b. Melakukan proses normalisasi data untuk mendapatkan interval data [0 1].
- c. Membuat inisialisasi jaringan yang akan dilatih untuk prediksi data yang akan datang.
- d. Proses pelatihan jaringan dengan fungsi *train*. Proses pelatihan ini dilakukan agar sistem *Neural Network* untuk mempelajari pola data dari

tahun 2004-2008 hingga mendapatkan performansi dan persentasi pencapaian target tahun 2009 yang terbaik.

- e. Menghitung keluaran jaringan tahun 2009 dari hasil pelatihan data tahun 2004-2008.

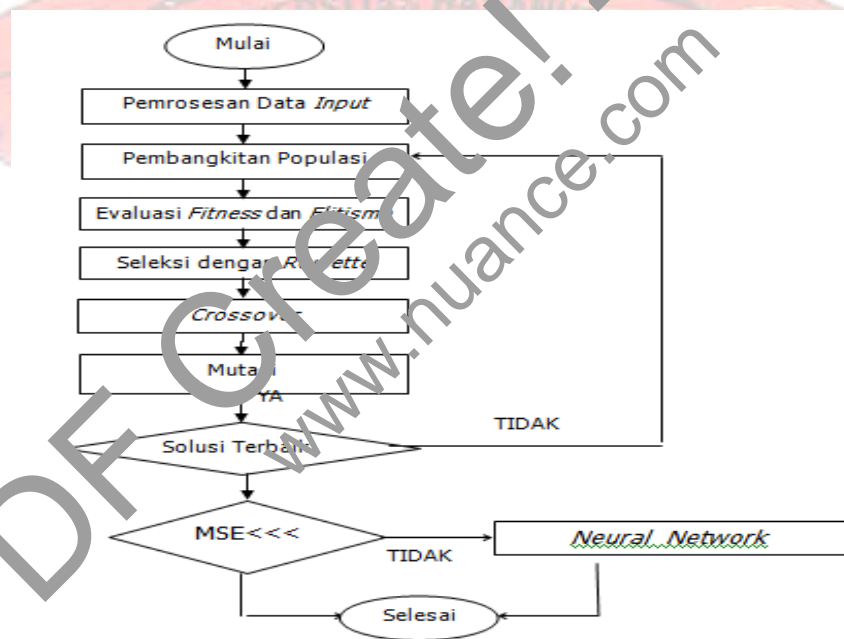


Gambar 42. Flowchart penelitian dengan metode GA-NN

Setelah melakukan proses pelatihan, proses pengujian akan dilakukan untuk mendapatkan prediksi variabel input. Langkah-langkah dalam proses pengujian *Neural Network-Back Propagation* adalah sebagai berikut:

- a. Memuat data setiap variabel input dari tahun 2005-2009 sebagai data uji, dimana jumlah tahun data latih sama dengan jumlah tahun data uji.
- b. Melakukan proses normalisasi data untuk mendapatkan interval data [0-1].
- c. Memasukkan data uji ke jaringan kemudian disimulasikan menggunakan net hasil pelatihan setiap variabel input tahun 2009.
- d. Menghitung keluaran jaringan sebagai hasil prediksi variabel input tahun 2010.

2. Validasi Curah Hujan Dengan *Genetic Algorithm-Neural Network*



Gambar 43. *Flowchart* perancangan sistem *Genetic Algorithm-Neural Network*.

a. Pemrosesan Data Input

Langkah–langkah dalam pemrosesan data input adalah sebagai berikut:

- 1) Memuat data hasil pelatihan *Neural Network* setiap variable yaitu temperatur, kelembaban, dan kecepatan angin pada bulan yang sama di tahun 2009 sebagai data input, sedangkan data target merupakan data curah hujan pada bulan yang sama di tahun 2010.
- 2) Melakukan proses normalisasi data untuk mendapatkan interval data [0-1].
- 3) Menentukan parameter-parameter *Genetic Algorithm* yang akan dipakai serta komponen-komponen untuk penanganan grafis, misalnya:
 - a) Ukuran populasi, yaitu banyaknya individu (data) yang terdapat dalam populasi. Pada penelitian dipakai ukuran populasi sebesar 200, artinya dalam sebuah populasi terdapat 200 individu.
 - b) Jumlah maksimum generasi, yaitu jumlah maksimum iterasi yang akan dijalankan pada *Genetic Algorithm*. Pada penelitian ini, generasi optimum uji adalah 2000 generasi sehingga pada generasi ke-2.000, individu dengan nilai *fitness* paling tinggi secara otomatis akan menjadi solusi dari permasalahan. Pembatasan ini untuk mengurangi waktu pemrosesan.
 - c) Probabilitas *crossover* (P_c), probabilitas mutasi (P_m), kedua parameter ini masing-masing menentukan besarnya kemungkinan individu untuk melakukan operasi *crossover*, dan mutasi. Pada penelitian ini $P_c=0,03$ dan $P_m =0,9$. Nilai ini adalah nilai optimum yang diperoleh melalui proses *trial-error*.

b. Pembangkitan Populasi Awal

Populasi awal dibangkitkan dari sekumpulan bilangan biner acak berdasarkan jumlah solusi yang diinginkan. Yang dimaksud solusi ialah bobot dan bias paling optimal yang akan menghasilkan nilai *Mean Square Error* (MSE) jaringan yang paling kecil. Populasi berisi sejumlah kromosom yang panjangnya sama, dibangkitkan berdasarkan jumlah kromosom dan jumlah gen. Ukuran populasi ditentukan berdasarkan banyaknya kromosom yang diinginkan dalam satu populasi, sedangkan jumlah gen ditentukan berdasarkan jumlah solusi yang diinginkan dan teknik pengkodean yang akan digunakan.

Pada penelitian ini, *Genetic Algorithm* dipakai untuk mencari nilai bobot dan bias sebuah jaringan *Feed Forward Neural Network* (FFNN) dengan jumlah *neuron* di *hidden layer* yang dipakai sama dengan jumlah *neuron* di *input layer* yaitu sebanyak tiga buah dan satu *neuron* di *output layer* sehingga jumlah variabel (bobot dan bias) yang dibutuhkan adalah sebanyak $(jumlah\ masukan + 1)^2$ dimana pada penelitian ini jumlah input sebanyak parameter unsur meteorologi yang digunakan, sehingga jumlah variabel dalam sebuah kromosom adalah sebanyak 16 buah gen, yaitu: sembilan buah bobot dan tiga buah bias dari *input layer* ke *hidden layer* serta tiga buah bobot dan sebuah bias dari *hidden layer* ke *output layer*.

Karena menggunakan *binary encoding*, maka setiap variabel akan dikodekan dalam bentuk biner yang panjangnya berdasarkan jumlah bit yang ditentukan. Misalnya dalam sebuah kromosom terdapat 16 buah variabel (gen)

sementara setiap variabel dikodekan dalam sepuluh bit, maka dalam sebuah kromosom terdapat 160 buah gen dimana variable pertama direpresentasikan oleh gen 1 sampai gen 10, variable kedua direpresentasikan oleh gen 11 sampai gen 20, dan seterusnya. Jika diinginkan agar dalam populasi terdapat 100 buah kromosom maka populasi akan berbentuk matrix berukuran 100 x 160.

c. Evaluasi Fitness dan *Elitisme*

Setiap individu dalam populasi akan dievaluasi dengan fungsi *fitness* sehingga memiliki nilai *fitness* masing-masing yang menjadi ukuran seberapa kuat individu tersebut untuk lolos ke generasi berikutnya. Yang dimaksud individu ialah kromosom yang isinya telah diubah dari bilangan biner menjadi bilangan real yang berada dalam interval yang ditentukan. Individu-individu hasil *decoding* tersebut akan dievaluasi berdasarkan fungsi *fitness* untuk mendapatkan nilai *fitness* setiap individu. Pada penelitian ini fungsi *fitness* yang digunakan ialah *Mean Square Error* (MSE), dengan demikian nilai *fitness*nya ialah $1/\text{MSE}$.

Elitisme ialah proses pembuatan duplikat kromosom yang memiliki nilai *fitness* tertinggi agar pada generasi berikutnya kromosom tersebut tidak hilang tetapi menjadi kromosom dengan nilai *fitness* minimum yang akan dioptimasi agar didapatkan kromosom yang nilai *fitness*nya lebih tinggi.

d. Seleksi dengan *Roulette Wheel*

Seleksi berfungsi untuk menentukan kromosom yang berhak melakukan operasi genetik. Adapun metode seleksi yang digunakan adalah *Roulette Wheel* dengan langkah-langkah sebagai berikut.

Pertama, dibuat interval nilai kumulatif (dalam interval $[0, 1]$) dari nilai *fitness* setiap kromosom dibagi total nilai *fitness* dari semua kromosom. Kromosom tersebut akan terpilih jika bilangan random yang dibangkitkan berada dalam interval akumulatifnya.

e. Operasi Crossover

Operasi *crossover* berupa proses pindah silang gen-gen antar kromosom induk agar dihasilkan kromosom anak. Pindah silang dilakukan berdasarkan probabilitas *crossover* (p_c) artinya pindah silang bisa dilakukan hanya jika suatu bilangan random yang dibangkitkan kurang dari p_c yang ditentukan, pada umumnya p_c diatur mendekati 1.

Pertama, dibangkitkan bilangan acak r bertipe *real* dalam *range* $[0, 1]$, jika $r < P_c$ maka kromosom-kromosom tersebut dapat melakukan *crossover*.

Pada penelitian ini, jenis *crossover* yang dipakai ialah *one-point crossover*. Satu titik potong dipilih secara random, kemudian bagian pertama dari orang tua 1 digabungkan dengan bagian kedua dari orang tua 2.

f. Operasi Mutasi

Operasi mutasi berupa proses perubahan gen dalam kromosom. Kromosom yang berhak melakukan operasi ini tergantung pada probabilitas mutasinya (P_m). Langkahnya adalah sebagai berikut:

- 1) Membangkitkan bilangan acak r bertipe *real* dalam *range* [0 1].
- 2) Jika $r < P_m$, maka semua individu dalam populasi terpilih untuk melakukan mutasi.

Pada penelitian ini, mutasi terjadi secara universal dalam kromosom, gen-gen yang terpilih untuk melakukan mutasi diubah nilainya: 0 menjadi 1 dan sebaliknya 1 menjadi 0.

g. Penentuan Suatu Kondisi Untuk Menghentikan Jalannya Algoritma.

Algoritma dengan sendirinya akan berhenti bila memenuhi kondisi berikut:

- Apabila generasi telah mencapai jumlah maksimum generasi yaitu 2.000 generasi, artinya pada generasi ke-2.000 individu dengan nilai *fitness* tertinggi akan terpilih secara otomatis sebagai solusi yang dicari.
- Apabila hasil prediksi yang dihasilkan oleh sistem *Genetic Algorithm* masih belum memenuhi kriteria ($MSE > 10^{-3}$), maka struktur FFNN (net) yang dihasilkan oleh *Genetic Algorithm* selanjutnya dilatih menggunakan *Neural Network-Back Propagation* untuk mendapatkan hasil prediksi yang lebih baik.

Proses pelatihan memiliki langkah-langkah yang sama pada proses pelatihan variabel input yang telah dibahas sebelumnya, tetapi dengan data input dan target yang berbeda. Net yang diperoleh dari pelatihan selanjutnya dimasukkan ke dalam jaringan sehingga dihasilkan output sistem yang merupakan hasil prediksi. Hasil prediksi dengan metode *Genetic Algorithm-*

Neural Network kemudian divalidasi dengan data curah hujan tahun 2009 dari BMKG untuk mengetahui keakuratan sistem dan nilai *Root Mean Square Error* (RMSE).

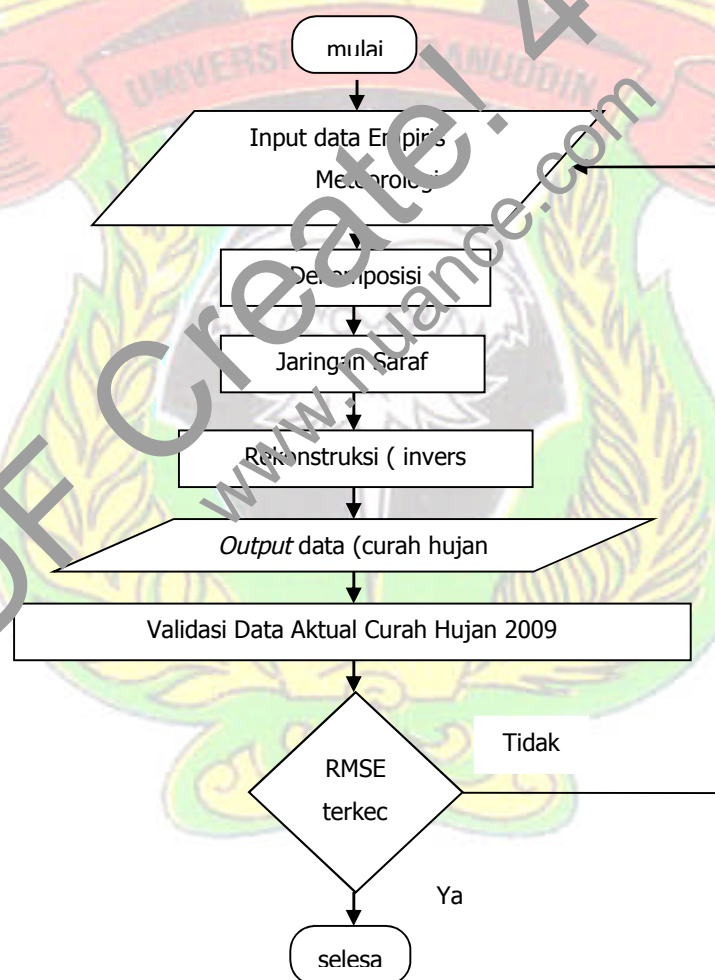
Struktur jaringan yang diperoleh dari proses pelatihan curah hujan dengan metode *Genetic Algorithm-Neural Network* selanjutnya diuji untuk mengetahui apakah stuktur jaringan tersebut dapat menghasilkan RMSE yang juga minimum meskipun data input berubah. Proses pengujian dilakukan dengan langkah-langkah sebagai berikut:

- 1) Memuat data hasil pengujian setiap variabel input, yaitu: temperatur, kelembaban, dan kecepatan angin (hasil produksi setiap variabel input tahun 2010).
- 2) Melakukan proses normalisasi data untuk mendapatkan interval data [0 1].
- 3) Memasukkan data hasil pengujian ke jaringan kemudian disimulasikan menggunakan net hasil pelatihan curah hujan tahun 2009.
- 4) Menghitung keluaran jaringan sebagai hasil prediksi curah hujan tahun 2010 kemudian divalidasi dengan data curah hujan tahun 2010 dari BMKG untuk mendapatkan nilai keakuratan dan nilai RMSE sistem.

F. Wavelet-NN

Sebelum membuat prediksi hal pertama yang harus dilakukan adalah membuat proses pelatihan, menentukan pola masukan dan target yang diinginkan.

1. Proses Pelatihan *Wavelet-Neural Network*



Gambar 44. Flowchart pelatihan *Wavelet Neural Network*

Pelatihan pada metode *back propagation* bertujuan agar jaringan dapat mengenali input yang diberikan sesuai target yang diinginkan. Proses pelatihan ini dilakukan berulang kali hingga mendapatkan *error* terkecil atau hingga batas iterasi yang ditentukan sehingga akan sesuai dengan data aktual yang diinginkan (target).

2. Pengolahan Data Inputan

Data inputan parameter unsur klimatologi yang diperoleh dari BMKG terlebih dahulu digolongkan sesuai unsur iklimnya masing-masing. Sebagai contoh, parameter angin dikelompokkan dari tahun 2004 hingga 2009 agar mempermudah dalam proses *load data*, seperti itu pula dalam pengolahan parameter yang lainnya. Setelah itu data kembali dikelompokkan berdasarkan bulannya dan diolah dalam bentuk *m-file* agar mempermudah dalam proses penginputan metode, sehingga data satu bulan telah terdapat data meteorologi dari tahun 2004-2009. Jadi, dalam setiap data per bulan terdapat lima data unsur yaitu angin, tekanan udara, kelembaban, temperatur, dan curah hujan dari tahun 2004-2009.

Dalam pembuatan program *wavelet*, langkah-langkah yang harus dilakukan adalah sebagai berikut:

a. Memuat data input

Memasukkan data input yang telah diolah dan disimpan dalam bentuk *m-file*.

- b. Menentukan jenis transform *wavelet*, yang digunakan pada metode ini adalah *Discrete Wavelet Transform (DWT)*. Hal ini disebabkan data inputan berupa diskrit.
- c. Menentukan *mother wavelet* yaitu *Daubechies*, dimana *Daubechies* sangat berguna dalam pengolahan data.

3. Neural Network

Hal pertama yang dilakukan adalah menentukan inputan dan targetnya. Dalam proses pelatihan, input yang dimaksud adalah data tahun 2004-2008 dan target yang diinginkan adalah curah hujan tahun 2009, dimana inputan dari *neural network* ini merupakan hasil keluaran dari *wavelet*.

Sebelum masuk ke dalam *Neural Network*, input dan target harus ditranspose terlebih dahulu, yaitu mengubah kolom menjadi baris. Hal ini agar *neural network* dapat mengenali dan mempermudah dalam sistem perhitungan jaringan.

Langkah-langkah dalam proses pelatihan *neural network* adalah sebagai berikut:

- a. Memuat data lima parameter (angin, tekanan udara, kelembaban, temperatur, dan curah hujan) dari tahun 2004 - 2009, dimana data training p_x (data input dari *wavelet*) merupakan data tahun 2004-2008 dan data t_x (data target) merupakan data tahun 2009.
- b. Melakukan proses normalisasi data untuk mendapatkan interval data [0 1]

- c. Membuat inisialisasi jaringan yang akan dilatih untuk prediksi data yang akan datang.
- d. Proses pelatihan jaringan dengan fungsi *train*. Proses pelatihan ini dilakukan agar sistem *neural network* mempelajari pola data dari tahun 2004-2008 hingga mendapatkan performansi dan persentasi pencapaian target tahun 2009 yang terbaik.
- e. Memvalidasikan keluaran jaringan tahun 2009 dari hasil pelatihan dengan data aktual curah hujan BMKG tahun 2009.

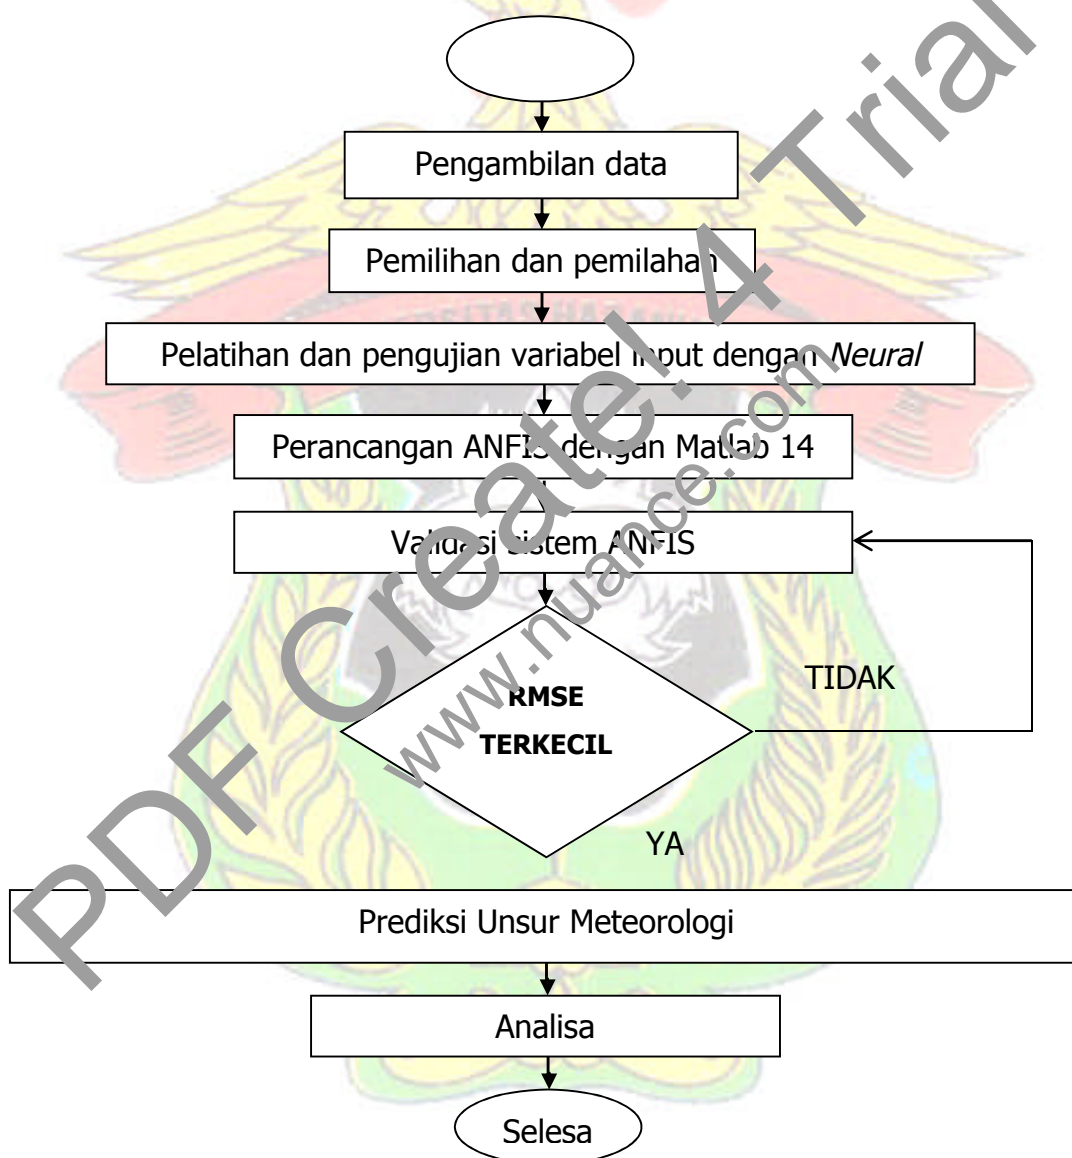
4. Proses Prediksi *Wavelet-Neural Network*

Proses prediksi dilakukan untuk menentukan hasil akhir (prediksi) dari metode ini. Proses yang terjadi sama halnya dengan proses pada pelatihan *wavelet-neural network*. Dimana inputan dan target dimasukkan terlebih dahulu ke dalam proses *wavelet* (dekomposisi) kemudian dilanjutkan dengan proses *neural network* selanjutnya dilakukan proses *wavelet* akhir (rekonstruksi).

Yang membedakan proses prediksi dengan proses pelatihan adalah data input dan target. Input yang digunakan adalah data dari tahun 2005-2009 dan yang menjadi target adalah curah hujan tahun 2010. Pada bagian proses *neural network*, tidak ada lagi proses *train* karena *neural network* telah mempelajari pola sebelumnya (pada proses pelatihan).

G. ANFIS

Langkah pertama untuk memprediksi curah hujan dengan metode ANFIS adalah membuat rancangan penelitian.



Gambar 45. Flowchart penelitian dengan metode ANFIS

Setelah mendapatkan sistem yang mendapatkan hasil validasi yang terbaik (mendekati 100 %) maka sistem tersebut yang berpotensi untuk memprediksi curah hujan. Untuk dapat memprediksi curah hujan tahun 2009 dan 2010 diperlukan teknik *neural network* untuk memprediksi variable *checking* input dari parameter meteorologi. Langkah-langkahnya dapat terlihat pada gambar 45.

1. Pengolahan Data

Dalam penelitian ini, data yang digunakan dibagi ke dalam dua kelompok, yaitu data *training* dan data *checking*. Data-data tersebut dibuat dalam bentuk matriks. Pada proses perancangan prediksi curah hujan menggunakan metode ANFIS, data *training* dan data *checking* disusun dalam bentuk matrik $N \times M$, di mana N adalah jumlah baris yang tergantung pada panjang data, sedangkan M adalah jumlah kolom ($M - 1$ kolom untuk vektor input yang akan ditraining dan kolom terakhir untuk vektor output). Selanjutnya dilakukan proses normalisasi yaitu dengan membagi masing-masing variabel input dan output dengan nilai variabel input dan output tertinggi selama pengukuran. Normalisasi dilakukan untuk mengurangi fluktuasi dan menghilangkan frekuensi tinggi.

2. Pengaturan Parameter Awal Pelatihan dan Pengujian ANFIS

a. *Epoch*

Epoch dapat diartikan sebagai tahap arah pembelajaran maju-mundur yang terjadi dalam jaringan adaptif. Misal satu tahap arah pembelajaran

maju-mundur dinamakan satu *epoch*. Program pelatihan dijalankan dengan *epoch* sesuai target *error* yang diinginkan.

b. Fungsi Keanggotaan

Fungsi keanggotaan *Fuzzy* input (premis) yang dipilih secara konvensional. Jenis fungsi keanggotaan pada penelitian ini adalah *gaussian* sebagai variabel input karena bentuk *gaussmf* cocok untuk data-data alami seperti data cuaca.

c. *Step Size*

Step Size atau ukuran langkah. Pengaturan *step size* adalah nilai 0.01. *Step size* sendiri dapat memberikan informasi langkah pelatihan dan pengujian disetiap *epoch*. Bila *step size* berubah akan menunjukkan perubahan kecepatan konvergensi dan identik dengan alur proses pelatihan/pembelajaran (*learning rate*). Secara pengamatan dapat memberikan efek terhadap perbaikan parameter dan epoch.

3. Pelatihan dan Pengujian Data Pada ANFIS

Prediksi melalui pemrograman fungsi matlab pada dasarnya melakukan perintah inialisasi sistem *Fuzzy*-nya. Persamaan yang biasa digunakan adalah GENFIS1, fungsi ini menghasilkan FIS tipe Sugeno dengan metode *grid partition*. ANFIS Sugeno merupakan model terbaik untuk analisis numerik dibanding model logika samar lainnya, karena dalam proses pembelajarannya (*training*) didasarkan pada upaya memperkecil nilai kesalahan dari output-nya. Adapun syntax selengkapnya adalah sebagai berikut:

$\text{InputFismat}=\text{genfis1}(\text{TrainData}, \text{NumMfs}, \text{MfType})$

TrainData, NumMFs dan MfType merupakan parameter yang dapat diisi sesuai dengan keinginan, seperti data yang dilatih, jumlah fungsi keanggotaannya (MFs) dan tipe Mfsnya. Fungsi GENFIS1 menghasilkan output linear.

Fungsi ANFIS pada pemrograman ini menggunakan algoritma pembelajaran *hybrid* untuk mengidentifikasi parameter-parameter fungsi keanggotaan untuk satu keluaran FIS tipe Sugeno.

Validasi data yang telah dilakukan pelatihan diperoleh dari pemanggilan fungsi EVALFIS. Fungsi ini akan memperlihatkan performa perhitungan *Fuzzy inference*.

4. Evaluasi Model ANFIS

Akhir pelatihan dan pengujian data yang telah mengalami beberapa *epoch* proses selalu menunjukkan ciri khas tanda-tanda bila pemrograman selesai melakukan langkah-langkah proses. Prediksi ANFIS dengan data observasi akan direpresentasikan dalam bentuk grafik dan linguistik. Reprerentasi model-model tersebut dapat membantu analisis dan pengamatan untuk mengambil asumsi kerja ANFIS.

5. Root Mean Square Error (RMSE)

Untuk mengevaluasi hasil percobaan dalam ANFIS ini digunakan pengukuran kesalahan (*error*) peramalan atau prediksi. RMSE digunakan

untuk mengevaluasi hasil prediksi ANFIS terhadap data observasi BMKG untuk melihat seberapa akurat hasil prediksi ANFIS.

Mean Square Error (RMSE) berikut:

$$RMSE = \frac{\sqrt{\frac{1}{N} \sum_{t=h}^N (y_t - \hat{y}_t)^2}}{y_{\max} - y_{\min}} \quad (18)$$

Dimana:

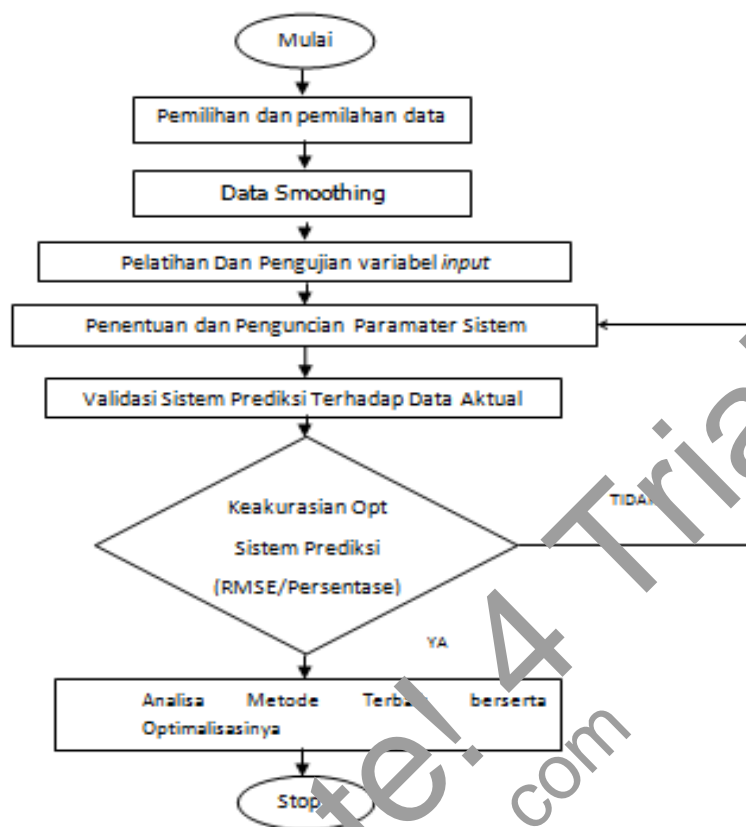
N : jumlah total data dan y merupakan nilai skalar data individu

H. Fuzi

Untuk prediksi variabel input digunakan *neural network*. Data yang telah dipilih dikelompokkan menggunakan metode *Fuzzy cluster means* agar di dapatkan parameter prenis awal pada sistem *Fuzzy logic*. Kemudian dilakukan perancangan sistem. *Fuzzy logic* menggunakan software Matlab

1. Perancangan *Fuzzy Logic*

Berikut adalah langkah-langkah perancangan *Fuzzy Logic* selengkapnya digambarkan pada *flowchart* berikut:



Gambar 46. *Flowchart* perancangan sistem *Fuzzy logic*

2. Penentuan *Space Data* Dengan Metode *Fuzzy Cluster Means*

Pengolahan data pada penelitian ini dilakukan eksperimen dengan berbagai sistem *Fuzzy logic*. Salah satu hal yang mempengaruhi sistem *Fuzzy logic* ini adalah data masukan. Unsur cuaca (meteorologi) yang memiliki korelasi terbesar yang akan digunakan sebagai masukan.

Pada penelitian ini pengelompokkan data menggunakan metode *Fuzzy cluster means* dari tahun 2004-2008 untuk validasi tahun 2009 dan *Fuzzy cluster means* dari tahun 2004-2009 untuk validasi tahun 2010. Variabel-variabel yang dikelompokkan dengan *Fuzzy cluster means* yaitu temperatur,

kelembaban, dan kecepatan angin. Curah hujan tidak dikelompokkan dengan *Fuzzy cluster means* karena sudah dikelompokkan menurut ketentuan BMKG.

Proses *clustering* berhenti ketika jumlah maksimum dari iterasi tercapai atau ketika perbaikan fungsi tujuan antara dua iterasi berturut-turut kurang dari jumlah minimum perbaikan ditentukan.

3. Fuzzifikasi

Fuzzifikasi adalah tahap pemetaan nilai masukan dan keluaran kedalam bentuk himpunan *Fuzzy*. Data masukan berupa himpunan *crisp* yang akan diubah menjadi himpunan *Fuzzy* berdasarkan *range* untuk setiap variabel masukannya. Pada proses fuzzifikasi ini terdapat dua hal yang harus diperhatikan yaitu nilai masukan dan keluaran serta fungsi keanggotaan (*membership function*) yang akan digunakan untuk menentukan nilai *Fuzzy* dari data nilai *crisp* masukan dan keluaran. Pada proses fuzzifikasi ini digunakan bentuk fungsi keanggotaan *gaussian* sebagai variabel masukan karena *gaussian* sesuai apabila digunakan untuk data-data alami seperti data cuaca. Disamping itu juga dipilih fungsi *gaussian* karena mempunyai tingkat keakurasian tinggi dalam membaca data dibandingkan fungsi lainnya. Proses iterasi dilakukan pada tahap fuzzifikasi, yaitu dengan merubah nilai *range* dan parameter yang digunakan untuk membangun fungsi keanggotaan, serta dapat juga dengan merubah jenis fungsi keanggotaan yang digunakan. Pada penelitian kali proses merubah nilai *range* dan parameter yang ada dari fungsi keanggotaan dilakukan hingga mendapatkan sistem dengan tingkat presisi

yang tinggi. Berikut adalah fungsi keanggotaan (*Membership function*) yang digunakan pada sistem *Fuzzy logic*.

4. Rule base

Setelah dilakukan *membership function*, maka langkah berikutnya yaitu membuat aturan (*rule base*). *Rule base* ini terdiri dari kumpulan aturan peramalan cuaca yang berbasis *Fuzzy logic* untuk menyatakan kondisi cuaca yang terjadi.

Tabel 3. Basis aturan prediksi hujan.

No	Temperatur (T)	Kelembaban (Rh)	Kecepatan Angin (Va)			
			Rg	Sd	Kg	SKg
1	Rd	Rd	Cr	Cr	Cr	Cr
2		Sd	Cr	Cr	Cr	Cr
3		Tg	HR	HS	HL	HSL
4	Sd	Rd	Cr	Cr	Cr	Cr
5		Sd	Cr	Cr	Cr	Cr
6		Tg	Cr	Cr	Cr	Cr
7	Tg	Rd	Cr	Cr	Cr	Cr
8		Sd	Cr	Cr	Cr	Cr
9		Tg	Cr	Cr	Cr	Cr

Penyusunan *rule base* ini berdasarkan pada sistem pakar yang ada, seperti terlihat pada tabel 3. Cara membaca *rule* pada tabel pada kolom berwarna biru “**IF T is Rendah AND Rh is Rendah AND Va is Ringan Then Cuaca Besok is Cerah**”.

Penyusunan *rule base* sangat berpengaruh pada presisi sistem, pada tahap pengambilan keputusan ditentukan berdasarkan rancangan *rule base*. Pada sistem perancangan prediksi hujan ini terdapat 36 *rule*. Proses iterasi juga dapat dilakukan dengan merubah aturan-aturan yang ada pada *rule base*, proses perubahan aturan-aturan dilakukan hingga mendapatkan sistem dengan tingkat presisi yang tinggi.

5. Inferensi *Fuzzy*

Proses inferensi *Fuzzy* adalah proses pengambilan keputusan untuk mendapatkan himpunan *Fuzzy logic* berdasarkan rancangan *rule base*. Nilai masukan yang teramati diolah untuk diidentifikasi aturan mana yang akan digunakan. Teknik pengambilan keputusan yang digunakan adalah metode Sugeno, karena metode ini bersifat intuitif, sehingga cocok untuk peramalan. Selain itu, komputasi juga akan efisien dan bekerja dengan baik untuk pengoptimalannya. Pada metode sugeno, dalam penerapannya menggunakan aturan operasi *AND* hal ini dikarenakan semua aturan saling bergantung dan mempengaruhi. Pada tahap pengambilan keputusan ini, nilai masukan yang berupa temperatur, kelembaban, kecepatan angin, dan tekanan masih berupa himpunan *crisp* yang nantinya akan diubah menjadi himpunan *Fuzzy* dengan fungsi keanggotaan yang berbeda-beda untuk setiap variabel. Dengan mengacu pada *rule base* diperoleh keluaran nilai *Fuzzy* berdasarkan besarnya nilai *Fuzzy* dari unsur meteorology yang digunakan.

6. Defuzzifikasi

Defuzzifikasi adalah pengkonversian setiap hasil dari *inference* sistem yang diekpresikan dalam bentuk *Fuzzy set* ke satu bilangan *real*. Hasil konversi tersebut merupakan keluaran yang diambil oleh sistem *Fuzzy logic*. Karena itu, pemilihan metode defuzzifikasi yang sesuai juga turut mempengaruhi sistem kendali *Fuzzy logic* dalam menghasilkan respon yang optimum.

7. Pengujian Sistem Prediksi dan Analisa

Pengujian dan analisa dilakukan untuk mengetahui apakah perancangan prediksi cuaca telah sesuai dengan tujuan yang ingin dicapai. Data hasil sistem *Fuzzy logic* 2009 divalidasi dengan data aktual tahun 2009 dari BMKG dan data hasil sistem *Fuzzy logic* 2010 divalidasi dengan data aktual tahun 2010. Valicasi sistem *Fuzzy logic* dilakukan dengan cara mencocokkan hasil keluaran dengan data aktual rata-rata per hari. Apabila hasil keluaran sistem sesuai dengan variabel linguistik data aktual, maka pada hari tersebut bernilai tepat. Begitu pula sebaliknya, apabila hasil keluaran sistem tidak sama dengan variabel linguistik (kualitatif) data aktual maka pada hari tersebut bernilai tidak tepat (*error*).


I. *Support Vector Machine – Fuzzy Logic (SVM-FL)*

Usulan kebaruan dalam disertasi ini adalah penggunaan SVM-FL untuk prediksi kualitatif curah hujan berdasarkan data empiris meteorologi. Pendekatan-pendekatan kuantitatif yang telah dibahas pada sub-bab sebelumnya telah mendekati tahap *state of the art* baik dari sisi kecerdasan buatan maupun pendekatan statistik.

Pendekatan kualitatif akan bermanfaat terutama jika diinginkan prediksi bukan dalam bentuk curah hujan (mm/hr) tetapi dalam suatu bentuk linguistic atau rentang tertentu yang dapat digunakan sebagai *Decision Support System* (DSS) utamanya dalam keilmuan manajemen sumber daya air.


1. Proposed System

SVM memiliki kehandalan dalam memprediksi data univariate berdasarkan data empiris yang sama. Dimana *Fuzzy Logic* mempunyai kapasitas dalam mengkonversi dan memetakan data multivariate menjadi univariate. Sehingga ide dalam disertasi ini adalah membangkitkan data prediksi harian dari masing-masing parameter meteorology yang kemudian akan dipetakan oleh *Fuzzy Logic* menjadi suatu keputusan linguistik besarnya curah hujan. Sistem yang diusulkan dapat terlihat pada gambar 47.



Gambar 47. Kombinasi SVM dan *Fuzzy Logic*

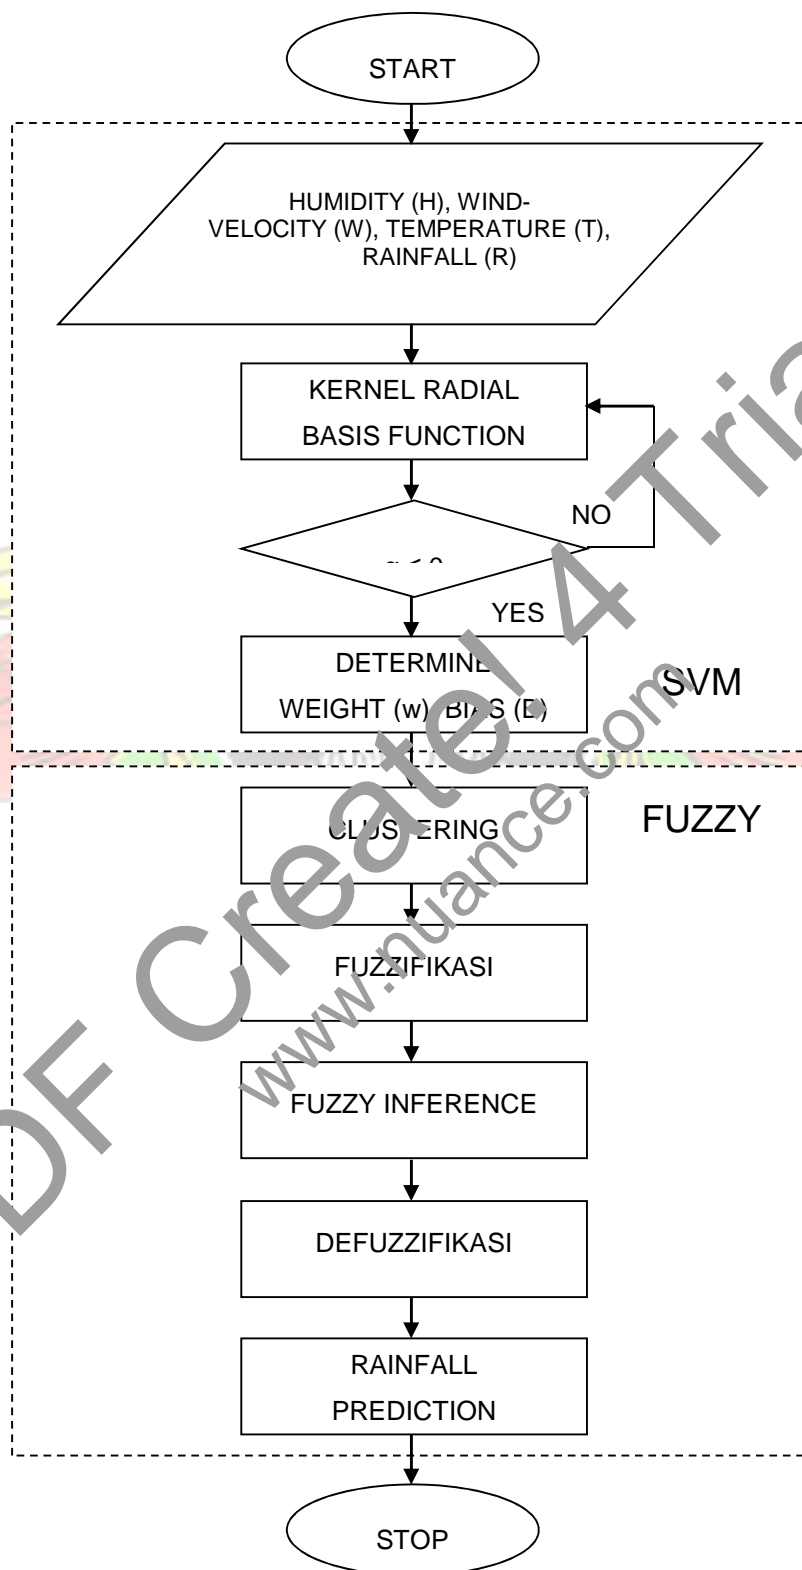
Dalam proses *Fuzzy logic* dibutuhkan basis pengetahuan yang terdiri dari basis data dan basis aturan. Basis data mendefinisikan himpunan *Fuzzy* atas ruang-ruang masukan dan keluaran. Basis aturan berisi aturan (*rule*) pengendalian proses.



Gambar 48. Posisi *rule base* pada alur *Fuzzy logic*

2. Unjuk Kerja Sistem

Unjuk kerja prediksi SVM-*Fuzzy* akan dibandingkan dengan dua teknik prediksi kualitatif lainnya yaitu JST-*Fuzzy* dan ANFIS. Akan dibandingkan presentase keberhasilan ketiga sistem dalam memprediksi rentang atau cluster curah hujan. Selain itu akan dibandingkan tren hasil prediksi terhadap data aktual bagi ketiga sistem.



Gambar 49. Flowchart SVM-Fuzzy Logic

Tahapan alur sistem SVM-Fuzzy logic yaitu:

- Mengklasifikasi variabel (*humidity, wind velocity, temperature, dan rainfall*) dengan menentukan garis/*hyperplane* sebagai pemisah berdasarkan metode SVM yang melihat jarak antara *hyperplane* dengan *pattern* terdekat dari variabel (*support vector*);
- Data klasifikasi yang bersifat non-linear akan diubah menjadi linear dalam *space* baru oleh Fungsi Kernel untuk memudahkan penentuan *weight* dan *bias* sebagai masukan untuk algoritma Fuzzy;
- Input data dari system SVM akan dikelompokkan dengan menggunakan metode *Fuzzy Cluster Means*.
- Penentuan himpunan nilai masukan dan keluaran melalui *membership function* dalam bentuk *crisp* berdasarkan *rule base* dari peramalan cuaca untuk menyatakan kondisi yang terjadi;
- Fuzzifikasi berfungsi untuk mengubah data masukan *crisp* ke dalam bentuk himpunan Fuzzy (derajat keanggotaan);
- *Fuzzy inference*/mekanisme penalaran Fuzzy dipergunakan untuk mengolah variabel-variabel masukan berdasarkan basis aturan (*rule*) ke dalam suatu himpunan Fuzzy keluaran dengan derajat keanggotaan yang telah ditetapkan;
- Defuzzifikasi atau FIS menggunakan model Sugeno, yaitu mengkonversi himpunan Fuzzy keluaran ke bentuk bilangan *crisp* dengan metode perhitungan rata-rata terbobot (*weighted average*);
- Hasil akhir adalah prediksi hujan yang akan dihitung validitasnya.

BAN IV

HASIL DAN PEMBAHASAN

A. Analisis Korelasi Variabel Input

Untuk mengukur kuat tidaknya hubungan antara variabel input terhadap variabel output yang diharapkan, maka pengujian korelasi penting dilakukan. Semakin kuat hubungan/korelasi antara variabel input terhadap variabel output, maka hasil prediksi yang didapatkan akan semakin akurat.

Telah dilakukan uji korelasi terhadap ke 6 (enam) variabel input, yaitu Temperatur, Kelembaban, Kecerahan Angin, Intensitas Sinar Matahari, Tekanan Udara dan Curah Hujan. Sebelumnya. Hasil pengujian ini selanjutnya digunakan dalam pemilihan variabel-variabel yang paling kuat korelasinya atau yang memiliki koefisien korelasi yang paling mendekati nilai 1 atau -1, sebagai variabel input untuk beberapa metode prediksi yang akan digunakan.

Korelasi antara variabel input dan output disajikan dalam bentuk koefisien korelasi yang diberikan pada persamaan (19) berikut:

$$\text{Correl}(X,Y) = \frac{\sum (x-\bar{x})(y-\bar{y})}{\sqrt{\sum (x-\bar{x})^2 \sum (y-\bar{y})^2}} \quad (19)$$

Dimana x dan y merupakan sampel rata-rata dari deret 1 dan rata-rata deret 2. Berikut ini disajikan data hasil uji korelasi antara variabel-variabel input.

Tabel dibawah ini menunjukkan hasil perhitungan korelasi kuadrat antara variabel uji dengan curah hujan pada tahun 2004 - 2008 yang dihitung secara manual dengan Ms excel.

Tabel 4. Hasil uji koefisien determinasi (r^2) parameter tahun 2004-2008

	KL	KA	IS	TU	TP
CH	0.049	0.032	0.005	0.017	0.039

Dimana:

CH : curah hujan

KL : kelembaban udara

KA : kecepatan angin

IS : intensitas sinar matahari

TU : tekanan udara

TP : temperatur luar ruangan

Berdasarkan tabel hasil uji koefisien determinasi atau korelasi kuadrat antara variabel-variabel yang mempengaruhi curah hujan, terlihat bahwa variabel yang memiliki koefisien tertinggi adalah kelembaban, temperatur, dan kecepatan angin, dengan nilai masing-masing 0.049, 0.039, dan 0.032. Jika nilai tersebut dikonversi menjadi koefisien korelasi maka nilainya menjadi 0.221, 0.198, dan 0.179 yang artinya ketiga variabel tersebut telah memenuhi kriteria korelasi antara 2 variabel (0.2) seperti yang ditunjukkan pada tabel 5.

Tabel 5. Koefisien korelasi antara 2 variabel

Koefisien korelasi	Tingkat korelasi
---------------------------	-------------------------

$\rho = 1$	korelasi positif sempurna
$0,80 \leq \rho < 1$	korelasi tinggi sekali
$0,60 \leq \rho < 0,80$	korelasi tinggi
$0,40 \leq \rho < 0,60$	korelasi sedang
$0,20 \leq \rho < 0,40$	Korelasi rendah
$0,00 < \rho < 0,20$	korelasi rendah sekali
$\rho = 0$	tidak mempunyai korelasi linier
$\rho = -1$	korelasi negatif sempurna
$-1 < \rho \leq -0,80$	korelasi negatif tinggi sekali
$-0,80 < \rho \leq -0,60$	korelasi negatif tinggi
$-0,60 < \rho \leq -0,40$	korelasi negatif sedang
$-0,40 < \rho \leq -0,20$	korelasi negative rendah
$-0,20 < \rho < 0$	korelasi negatif rendah sekali
Makin jauh ρ dari 0	korelasi akan semakin tinggi

Dari uji simulasi juga ditemukan bahwa dengan hanya memasukkan ke tiga parameter meteorologi kelembaban, temperatur, dan angin maka tingkat prediksi dapat meningkat. Data yang digunakan adalah data tahun 2004–2010, dengan rincian:

- Data tahun 2004–2008 digunakan untuk meramalkan Curah Hujan tahun 2009.
- Data tahun 2004–2009 digunakan untuk meramalkan Curah Hujan tahun 2010.

B. Distribusi Data Curah Hujan Berdasarkan Rekayasa

Hidrologi

Dalam penerapan keilmuan Teknik sipil dikenal ilmu rekayasa hidrologi yang dapat menghitung prediksi tingginya curah hujan di masa datang yang disebut analisis hujan rencana berdasarkan tahun ulang. Salah satu teknik dalam menganalisis hujan rencana yaitu dengan metode *Gumble*. Berikut akan dilakukan perhitungan analisis hujan rencana dengan menggunakan data curah hujan tahun 2004-2008 kemudian distribusi frekuensi curah hujan tersebut akan diuji kesesuaiannya dengan metode *Chi Square*.

Tabel 6. Perhitungan kuadrat data tinggi hujan

TAHUN	X (mm)	X ² (mm)
2004	132	19321
2005	108	11664
2006	133	19321
2007	129	16641
2008	157	24649
Σ	672	91596

$$\bar{X} \text{ rata-rata} = \frac{\Sigma X}{n} = \frac{672}{5} = 134.4$$

$$(\bar{X} \text{ rata-rata})^2 = (134.4)^2 = 18063.36$$

$$\bar{X}^2 \text{ rata-rata} = \frac{\Sigma X^2}{n} = \frac{91596}{5} = 18319.2$$

$$\sigma_X = \sqrt{\bar{X}^2 \text{ rata-rata} - (\bar{X} \text{ rata-rata})^2} = \sqrt{18319.2 - 18063.36} = 15.995$$

Berdasarkan tabel untuk tahun ulang pada metode *Gumble* untuk $n = 5$ diperoleh:

$$Y = 0.2935 \quad \sigma Y = 0.862$$


$$- = - = \frac{\cdot}{\cdot} = 18.56$$

$$b = X - - Y = 128.95$$

sehingga

$$X = 18.56 Y + 128.95$$

Jadi untuk tahun ulang t maka substitusi Y saat t untuk sesuai tabel untuk tahun ulang pada metode Gumble. Hasil perhitungan curah hujan untuk tahun ulang dapat dilihat pada grafik di bawah ini.



Gambar 50. Grafik curah hujan tinggi pada periode ulang Metode gumble untuk menghitung curah hujan 2004-2008 pada tahun

ulang menghasilkan persamaan:

$$X = 18.56 Y + 128.95$$

Akan tetapi persamaan tersebut harus diuji terlebih dahulu distribusi frekuensinya untuk melihat kesesuaian dengan metode *Chi Square*. Tabel di bawah ini memperlihatkan perhitungan variabel yang digunakan dalam metode *Chi Square*.

Tabel 7. Variabel dalam perhitungan distribusi frekuensi metode *Chi Square*

RUMUS	KETERANGAN	HASIL
$k = 1 + 3.322 \log n$	$n = 5$ tahun	$k = 4$
$dk = k - R - 1$	R gumbel = 1	$dk = 2$
$Ef = n / k$		$Ef = 1.25$
$Dx = (X_{max} - X_{min}) / (k - 1)$	$X_{max} = 157, X_{min} = 108$	$Dx = 16.33$
$X_{awal} = X_{min} - (0.5 \times 16.33)$		$X_{awal} = 99.835$
$\alpha = 0.05, R = 2$		$X^2 = 5.991$

Berdasarkan tabel di atas maka diperoleh tabel distribusi frekuensi curah hujan sebagai berikut:

Tabel 8. Distribusi frekuensi curah hujan dengan metode *Chi Square*

NILAI BATASAN	Of	Ef	(Of-Ef) ²	((Of-Ef) ²)/Ef
$99.835 \leq X < 116.165$	1	1.25	0.0625	0.05
$116.165 \leq X < 132.495$	1	1.25	0.0625	0.05
$132.495 \leq X < 148.825$	2	1.25	0.5625	0.45
$148.825 \leq X < 165.155$	1	1.25	0.0625	0.05
Σ				0.6

Terlihat bahwa hasil distribusi $0.6 < 5.991$, sehingga dapat dikatakan bahwa metode Gumble yang digunakan tersebut memenuhi kriteria.

C. Hasil Prediksi Curah Hujan Tahunan Metode Kuantitatif

1. ARIMA (*Autoregressive Integrated Moving Average*)

Pada metode ini, langkah pertama yang dilakukan adalah mendapatkan data yang stasioner untuk memperoleh hasil prediksi yang akurat. Setelah data sudah stasioner maka selanjutnya akan dicoba untuk mengidentifikasi model ARIMA (p, d, q).

Untuk menentukan orde (d) pada ARIMA, maka dibutuhkan hasil pembeda (*difference*) pertama untuk salah satu variabel input yang digunakan.

Data yang digunakan untuk proses pembeda adalah dari tahun 2004 sampai dengan 2008 untuk mendapatkan persamaan model ARIMA tahun 2009.


Contoh proses pembeda pertama bulan Februari dapat terlihat pada tabel 6. Variasi pembeda mulai dari -25 sampai dengan 26. Diharapkan hasil ini telah menunjukkan pembeda pertama mencapai distribusi normal.

Tabel berikut menyajikan hasil *difference* pertama dari data kelembaban bulan Februari tahun 2004 sampai tahun 2008. Selanjutnya akan ditentukan kembali nilai-nilai koefisien autokorelasi dan dari data tersebut.

Tabel 9. *Difference* pertama kelembaban bulan Februari tahun 2004-2008


Bulan / tahun	Pembeda1	Bulan / tahun	Pembeda1	Bulan / tahun	Pembeda1	Bulan / tahun	Pembeda1	Bulan / tahun	Pembeda1
1/2004	4	1/2005	-4	1/2006	5	1/2007	6	1/2008	-1
2/2004	3	2/2005	-4	2/2006	-3	2/2007	-3	2/2008	15

3/2004	3	3/2005	-1	3/2006	-1	3/2007	-2	3/2008	-4
4/2004	1	4/2005	1	4/2006	-3	4/2007	-2	4/2008	1
5/2004	0	5/2005	-7	5/2006	3	5/2007	6	5/2008	-4
6/2004	0	6/2005	-2	6/2006	2	6/2007	-7	6/2008	-4
7/2004	0	7/2005	6	7/2006	-2	7/2007	0	7/2008	5
8/2004	2	8/2005	-2	8/2006	4	8/2007	-6	8/2008	-1
9/2004	-5	9/2005	1	9/2006	-7	9/2007	0	9/2008	-4
10/2004	-3	10/2005	12	10/2006	-4	10/2007	5	10/2008	8
11/2004	1	11/2005	-7	11/2006	4	11/2007	-6	11/2008	1
12/2004	8	12/2005	-1	12/2006	-4	12/2007	-3	12/2008	-10
13/2004	-1	13/2005	1	13/2006	-4	13/2007	5	13/2008	9
14/2004	1	14/2005	3	14/2006	2	14/2007	1	14/2008	-1
15/2004	0	15/2005	-5	15/2006	0	15/2007	-19	15/2008	-7
16/2004	-1	16/2005	1	16/2006	9	16/2007	26	16/2008	8
17/2004	-2	17/2005	-1	17/2006	2	17/2007	-8	17/2008	-7
18/2004	0	18/2005	-8	18/2006	0	18/2007	-1	18/2008	-1
19/2004	1	19/2005	3	19/2006	5	19/2007	-1	19/2008	-3
20/2004	1	20/2005	1	20/2006	0	20/2007	7	20/2008	5
21/2004	1	21/2005	-1	21/2006	-3	21/2007	1	21/2008	9
22/2004	-25	22/2005	5	22/2006	0	22/2007	-3	22/2008	-16
23/2004	25	23/2005	0	23/2006	6	23/2007	-7	23/2008	-3
24/2004	0	24/2005	4	24/2006	-6	24/2007	4	24/2008	13
25/2004	0	25/2005	-6	25/2006	-9	25/2007	11	25/2008	-2
26/2004	1	26/2005	5	26/2006	-1	26/2007	-10	26/2008	-5
27/2004	-2	27/2005	4	27/2006	16	27/2007	6	27/2008	4
28/2004	-1	28/2005	-7	28/2006	-4	28/2007	-9	28/2008	-2



Gambar 51. Grafik koefisien autokorelasi pembeda pertama kelembaban.

Gambar diatas adalah grafik beserta nilai-nilai koefisien Autokorelasi dari data tersebut, dimana ACF akan menentukan AR pada metode ARIMA. Sebagai pelengkap nilai koefisien koefisien autokorelasi, maka dilakukan perhitungan koefisien autokorelasi parsial. Berikut adalah grafik koefisien autokorelasi parsial beserta nilai-nilai dari koefisien autokorelasi parsial dari data pembeda pertama.



Gambar 52. Koefisien parsial autokorelasi pembeda pertama kelembaban.

Gambar diatas adalah grafik beserta nilai-nilai koefisien Parsial Autokorelasi dari data tersebut, di mana PACF akan menentukan MA pada metode ARIMA.

Dari grafik autokorelasi diff 1 dapat dilihat bahwa nilai-nilai koefisien autokorelasi yang tidak signifikan dgn r_k sebanyak 4 lag, maka estimasi orde dari proses autoregressive adalah satu atau **AR(3)**.

Untuk proses MA (moving average) terlihat bahwa nilai-nilai koefisien autokorelasi parsial mengalami penurunan secara eksponensial menuju nol dan terdapat 3 koefisien autokorelasi yang tidak signifikan, sehingga estimasi orde MA yaitu satu atau **MA(5)** dapat diterima. Untuk sementara model yang dapat diidentifikasi adalah ARIMA (3, 0, 5). Karena data yang dipakai adalah data hasil difference 1 maka model tersebut menjadi **ARIMA(3, 1, 5)**.

Diperoleh model ARIMA sebagai berikut.

ARIMA (3, 1, 5)

$$(1 - B)(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3) = \theta_0 + (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \theta_4 B^4 - \theta_5 B^5)\varepsilon_t \quad (20)$$

114

$$\begin{array}{l} \text{Difference 1} \quad \text{AR(3)} \quad \text{MA(5)} \\ [1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - B + \phi_1 B^2 + \phi_2 B^3 + \phi_3 B^4]Y_t \\ = \theta_0 + \varepsilon_t - \theta_1 B\varepsilon_t - \theta_2 B^2\varepsilon_t - \theta_3 B^3\varepsilon_t - \theta_4 B^4\varepsilon_t - \theta_5 B^5\varepsilon_t \end{array} \quad (21)$$

$$Y_t = Y_{t-1} + \phi_1 Y_{t-1} - \phi_1 Y_{t-2} + \phi_2 Y_{t-2} - \phi_2 Y_{t-3} + \phi_3 Y_{t-3} - \phi_3 Y_{t-4} + \theta_0 - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3} + \theta_4 \varepsilon_{t-4} - \theta_5 \varepsilon_{t-5} + \varepsilon_t \quad (22)$$

$Y_t =$

$$\begin{array}{l} Y_{t-1} + 0.5777Y_{t-1} - 0.5777Y_{t-2} + 0.0983Y_{t-2} - 0.0983Y_{t-3} + 0.7055Y_{t-3} - \\ 0.7055Y_{t-4} + 0.01794 - 0.0578\varepsilon_{t-1} - 0.3629\varepsilon_{t-2} - 0.8652\varepsilon_{t-3} + 0.3456\varepsilon_{t-4} - \\ 0.0451\varepsilon_{t-5} + \varepsilon_t \end{array} \quad (23)$$

Persamaan diatas adalah model dari ARIMA (3,1,5).

Tabel 10. Hasil prediksi kelembaban bulan Februari Tahun 2009 dan 2010

TGL	TAHUN 2009		TAHUN 2010	
	Real Februari	Prediksi Februari	Real Februari	Prediksi Februari
1	97	92.213	91	93.038
2	97	88.088	97	88.823
3	100	90.477	95	92.591
4	96	92.349	92	91.93
5	91	88.16	85	89.177
6	86	92.1	91	93.83
7	86	91.575	91	90.682
8	83	88.553	84	90.119
9	82	93.148	86	94.054
10	92	90.438	89	89.633
11	97	89.138	88	91.421
12	98	93.541	88	93.617
13	88	89.375	85	89.071
14	100	90.691	90	92.761
15	87	93.254	91	92.644
16	85	88.722	94	89.159
17	85	92.035	82	93.805
18	86	92.393	86	91.399
19	88	88.681	88	89.892
20	81	93.145	91	94.295
21	87	91.202	91	90.219
22	96	89.285	89	91.095
23	86	93.75	88	94.114
24	95	90.006	83	89.427
25	95	90.396	84	92.474
26	99	93.707	89	93.323
27	92	89.132	83	89.244
28	84	91.742	84	93.685

Untuk menentukan hubungan kelembaban, temperatur, dan angin terhadap curah hujan, digunakan analisis regresi berganda.

Tabel 11. Prediksi temperatur, kelembaban, angin 1 Februari 2009

Prediksi Temperatur (°C)	Prediksi Kelembaban (%)	Prediksi Angin (knot)
26.6774	92.213	21.2563

Setelah mencari hubungan temperatur, kelembaban, angin terhadap curah hujan dengan *software* minitab, maka akan terbentuk suatu persamaan:


$$\begin{aligned} \text{Curah hujan} &= 1055 - 2.72 \text{ kelembaban} - 32.4 \text{ temperatur} + 3.53 \text{ angin} \\ &= 14.867619 \end{aligned}$$

Jadi prediksi hujan 1 Februari 2009 adalah 14.867619 mm.

Pada tabel 9 memperlihatkan hasil prediksi curah hujan menggunakan metode ARIMA untuk Bulan Januari 2009 dan 2010. Sementara Gambar selanjutnya memperlihatkan grafik perbandingan antara hasil prediksi curah hujan menggunakan metode ARIMA dengan data aktual curah hujan untuk bulan Januari 2009 dan 2010.

Tabel 12. Hasil prediksi curah hujan menggunakan metode ARIMA, bulan Januari 2009 dan 2010

Tanggal	Januari 2009		Januari 2010	
	Prediksi (mm)	Aktual (mm)	Prediksi (mm)	Aktual (mm)
1	14,86	67	46,81	14
2	17,14	29	20,94	0
3	36,3	27	43,80	2
4	20,87	2	16,91	7
5	7,48	9	22,39	72
6	3,42	7	21,73	56
7	8,23	2	4,38	16
8	8,96	43	21,08	19
9	67,25	74	31,78	7
10	55,22	58	39,26	78
11	51,45	59	8,42	30
12	35,3	22	13,23	42
13	11,6	45	15,62	48
14	33,01	45	62,91	90
15	22,65	12	24,71	103
16	27,2	31	33,14	9
17	30,09	5	22,59	29
18	42,49	46	33,35	39
19	20,22	21	16,04	31
20	40,45	21	31,19	62
21	0	7	0	34
22	10,13	0	11,27	7
23	3,83	1	3,72	0
24	29,9	4	15,02	1
25	15,04	1	31,56	7
26	0	2	0	7
27	0	5	0	3
28	4,04	27	54,55	20
29	8,8	2	7,48	16
30	81,98	89	37,35	110
31	71,35	74	183,32	49



Gambar 53. Grafik perbandingan hasil prediksi curah hujan menggunakan metode ARIMA (a) Januari 2009 ; (b) Januari 2010

➤ RMSE ARIMA

$$RMSE = \frac{\sqrt{\frac{1}{N} \sum_{t=h}^N (y_t - \hat{y}_t)^2}}{y_{\max} - y_{\min}}$$

$$RMSE = 0,2392$$

2. ASTAR (*Adaptive Splines Threshold Autoregression*)

Pada metode ini, dalam perancangan prediksi curah hujan pada tahun tertentu, perlu dilakukan validasi data aktual 1 tahun sebelumnya. Dari data yang ada, akan ditentukan hubungan antar variabel input, yaitu kelembaban, temperatur, dan kecepatan angin terhadap curah hujan. Untuk mendapatkan model yang optimum, yaitu model yang mampu menjelaskan keseragaman data dan mempunyai ketepatan tinggi saat validasi model, dilakukan simulasi dengan masukan model *MARS*.

Hasil simulasi pada Bulan Februari sebagai sampel penelitian Tahun 2009 dan 2010, menunjukkan jumlah basis fungsi maksimum = 11 dimana rentang jumlah basis fungsinya adalah 2 – 4 kali variabel prediktor yaitu antara 6 – 12 basis fungsi, maksimum interaksinya = 1, dan minimum observasi pada setiap jumlah basis fungsi = 0. Untuk mendapatkan jumlah basis fungsi maksimum menggunakan metode *forward stepwise*.

Tabel 13. Jumlah basis fungsi tahun 2009 dengan variabel Y terhadap X

Basis Fungsi	Nilai GCV	Variabel	Knot
0	957,230	-	
2 1	831,370	Temperatur (X_3)	24,3
4 3	785,592	Angin (X_1)	12
5	804,703	Kelembaban (X_2)	69
7 6	822,173	Kelembaban (X_2)	98
9 8	854,737	Kelembaban (X_2)	95
11 10	889,958	Kelembaban (X_2)	96

Tabel 14. Jumlah basis fungsi tahun 2010 dengan variabel Y terhadap X

Basis Fungsi	Nilai GCV	Variabel	Knot
0	984,431	-	
2 1	855,972	Temperatur (X_3)	24,3
4 3	822,635	Angin (X_1)	12
5	834,093	Kelembaban (X_2)	69
7 6	845,732	Temperatur (X_3)	24,7
9 8	864,023	Temperatur (X_3)	24,1
11 10	896,243	Angin (X_1)	14

Dari tabel diatas terlihat bahwa nilai basis fungsi maks. adalah 11. Uji signifikansi yang dilakukan secara bersamaan terhadap basis fungsi-basis fungsi yang terdapat dalam model MARS ini bertujuan untuk mengetahui model MARS yang terpilih dan menunjukkan hubungan yang tepat antara variabel prediktor (temperature, kelembaban, dan angin) dengan variabel respon (curah hujan). Software MARS akan menghasilkan persamaan fungsi yang baik untuk memprediksi dengan nilai *Generalized Cross Validation (GCV)* paling terkecil.

Pemilihan nilai knot didasarkan pada nilai GCV terkecil yang diperoleh dari software MARS. Yang perlu digaris bawahi adalah setiap satu nilai knot akan menghasilkan dua basis fungsi berpasangan dengan jumlah interaksinya adalah 1 sehingga pada tabel terlihat pasangan basis 2-1, 4-3, 7-6, 9-8, dan 11-10. Sedangkan untuk basis fungsi 5 tidak berpasangan karena jumlah basis fungsi maks. hanya 11 dan juga adanya proses *backward stepwise* yang meminimumkan nilai GCV yang terkecil dari jumlah basis fungsi yang dihasilkan oleh *forward stepwise* menyebabkan nilai GCV pada basis 5 sampai 11 mengalami kenaikan yang berbanding terbalik dengan basis 0 sampai 4.

Selanjutnya untuk menghasilkan model *MARS*, jumlah basis fungsi maksimum yang telah diperoleh akan dipilih dengan menggunakan metode *backward stepwise* atau metode *Penalized Residual Sum of Square* dengan hasil sebagai berikut:

Tabel 15. Model variabel respon Y terhadap X Tahun 2009

Basis Fungsi	Koefisien	Variabel	Nilai GCV	Knot
0	-9,296	-	785,046	-
2	36,493	Temperatur (X_3)		24,3
4	5,351	Angin (X_1)		12
5	1,302	Kelembaban (X_2)		69

Tabel 16. Model variabel respon Y terhadap X Tahun 2010

Basis Fungsi	Koefisien	Variabel	Nilai GCV	Knot
0	-12,204	-	821,112	-
2	32,570	Temperatur (X_3)		24,2
4	4,995	Angin (X_1)		12
5	1,493	Kelembaban (X_2)		69

Setelah diperoleh jumlah basis fungsi dengan nilai GCV terkecil, maka selanjutnya dilakukan proses *relative variabel importance* yaitu suatu proses untuk mengetahui besarnya pengaruh variabel-variabel prediktor terhadap variabel respon dan dari kalkulasi data model *MARS* diperoleh nilai kepentingan variabel prediktor terhadap curah hujan.

Tabel 17. Nilai Kepentingan Tahun 2009 X terhadap Y

Variabel	Nilai Kepentingan	GCV
Temperatur (X_3)	100	867,886
Kelembaban (X_2)	63,078	818,007
Angin (X_1)	61,363	816,239

Tabel 18. Nilai Kepentingan Tahun 2010 X terhadap Y

Variabel	Nilai Kepentingan	GCV
Temperatur (X_3)	100	880,847
Kelembaban (X_2)	96,120	876,302
Angin (X_1)	56,202	839,980

Penunjukkan kontribusi murni variabel prediktor terhadap basis fungsi bertujuan untuk melihat berapa besar pengaruhnya terhadap model hujan, seperti kurva temperatur, kelembaban, dan angin. Tetapi untuk mendapatkan model terbaik dari prediksi hujan yang dihasilkan, tidak semua variabel prediktor tersebut digunakan. Hanya variabel yang secara signifikan mempengaruhi kondisi keesokan harinya dilihat dari adanya nilai *variable importance* yang diolah menggunakan software MARS yang terpilih.

Rumus umum untuk model prediksi curah hujan berdasarkan pemodelan ASTAR yaitu:

$$Y = |kBF_0 + kBF_2 * BF_2 + kBF_4 * BF_4 + kBF_5 * BF_5| \quad (24)$$

$$Y = |kBF_0 + kBF_2 * (VP_1 - TK_1) + kBF_4 * (VP_2 - TK_2) + kBF_5 * (TK_3 - VP_2)| \quad (25)$$

Dimana:

kBF : koefisien basis fungsi

VP : variabel prediktor

TK : titik knot

Dengan mengacu pada rumus diatas maka model persamaan untuk prediksi tahun 2009 yaitu:

$$Y = |-9.296 + 36.493 * BF_2 + 5.351 * BF_4 + 1.302 * BF_5|$$

Dengan,

$$BF_2 = \max(0, 24.200 - \text{Temperatur});$$

$$BF_4 = \max(0, 12.000 - \text{Angin}_{X1});$$

$$BF_5 = \max(0, \text{Kelembaban} - 69.000);$$

$$\text{Model Hujan}_{FE} = BF_2 BF_4 BF_5$$

Sedangkan untuk prediksi Tahun 2010, model persamaan:

$$Y = |-12.204 + 32.570 * BF_2 + 4.995 * BF_4 + 1.493 * BF_5|$$

Dengan,

$$BF_2 = \max(0, 24.3 - \text{Temperatur});$$

$$BF_4 = \max(0, 12 - \text{Angin});$$

$$BF_5 = \max(0, \text{Kelembaban} - 69)$$

$$\text{Model Hujan } Y = BF_2 BF_4 BF_5$$

*** Contoh perhitungan untuk prediksi 1 Februari 2010**

Temperatur = 27.2; angin = 12; kelembaban = 100

Nilai tersebut merupakan variabel prediktor yang diperoleh dari data BMKG untuk tahun 2004-2009 dan terpilih berdasarkan hasil persamaan *best model* untuk tanggal 1 Februari dari tahun 2004-2009 yang diolah dalam

software dan juga memiliki nilai *Generalized Cross Validation (GVC)* terkecil dibanding model lainnya khusus untuk data tanggal 1 Februari. Model ini dihitung secara manual melalui software berdasarkan model hujan (Y) terbaik yang diperoleh dari jumlah basis fungsi tiap harinya.


Sehingga untuk melihat hasil prediksi tanggal 1 Februari 2010 maka substitusi kembali nilai variabel prediktor tersebut ke dalam model persamaan prediksi tahun 2010.

$$Y = -12.204 + 32.570 * BF_2 + 4.995 * BF_4 + 1.493 * BF_5$$

$$Y = -12.204 + 32.570 * (24.3 - 27.2) + 4.995 * (12 - 12) + 1.493 * (100 - 69)$$

$$Y = -60.374 \rightarrow 60.374 \text{ mm}$$

merupakan hasil prediksi yang mendekati nilai aktual 55 mm pada tanggal 1 Februari 2010.



(a)

(b)

Gambar 54. Grafik perbandingan hasil prediksi curah hujan menggunakan metode ASTAR dengan data aktual (a) Januari 2009 ; (b) Januari 2010

Tabel 19. Hasil prediksi curah hujan menggunakan metode ASTAR Januari

Tanggal	Januari 2009		Januari 2010	
	Prediksi (mm)	Aktual (mm)	Prediksi (mm)	Aktual (mm)
1	67,2	67	13,1	14
2	28,9	29	3,6	0
3	33,3	27	3,2	2
4	6,8	2	13,1	7
5	12,7	9	62,4	72
6	15,6	7	44,5	56
7	3,8	2	14,4	15
8	39,2	43	12,8	19
9	76,1	74	23,2	17
10	58,4	58	66,5	78
11	39,2	59	33,4	30
12	24,5	22	37,9	42
13	46,6	45	43,1	48
14	46,6	45	60,5	90
15	42,2	42	66,2	103
16	31,3	31	8,7	9
17	42,5	54	33,5	29
18	46,5	46	31,4	39
19	8,6	21	31,2	31
20	20,0	21	63,5	62
21	8,2	7	33,6	34
22	0,9	0	40,2	7
23	2,4	1	8,9	0
24	6,8	4	0,3	1
25	0,6	1	14,4	7
26	0,9	2	5,5	7
27	5,3	5	8,0	3
28	28,9	27	27,7	20
29	2,4	2	19,8	16
30	90,8	89	3,4	110
31	76,1	74	46,9	49

Gambar 53 memperlihatkan grafik perbandingan antara hasil prediksi curah hujan menggunakan metode ASTAR dengan data aktual curah hujan untuk bulan Januari 2009 dan 2010.

➤ RMSE ASTAR

$$RMSE = \frac{\sqrt{\frac{1}{N} \sum_{t=h}^N (y_t - \hat{y}_t)^2}}{y_{\max} - y_{\min}} = 0,0243$$

Dan persentase keakuratan-keakuratan sebesar 91,8%

3. Genetic Algorithm–Neural Network

Metode ini merupakan gabungan dari metode *Genetic Algorithm* (GA) dan *Neural Network* (NN), dimana hasil prediksi dari metode NN merupakan input metode GA. Diakukan training data untuk ketiga variabel input yang digunakan dan menghasilkan prediksi terhadap variabel input oleh metode NN.

Tabel 8 merupakan hasil prediksi metode NN dengan sampel yang diambil adalah nilai temperatur bulan maret yang akan menjadi input dan training data pada metode GA. Sedangkan hasil prediksi untuk tahun 2009 terhadap variabel input metode NN untuk ketiga variabel input yang digunakan diberikan pada tabel 17.

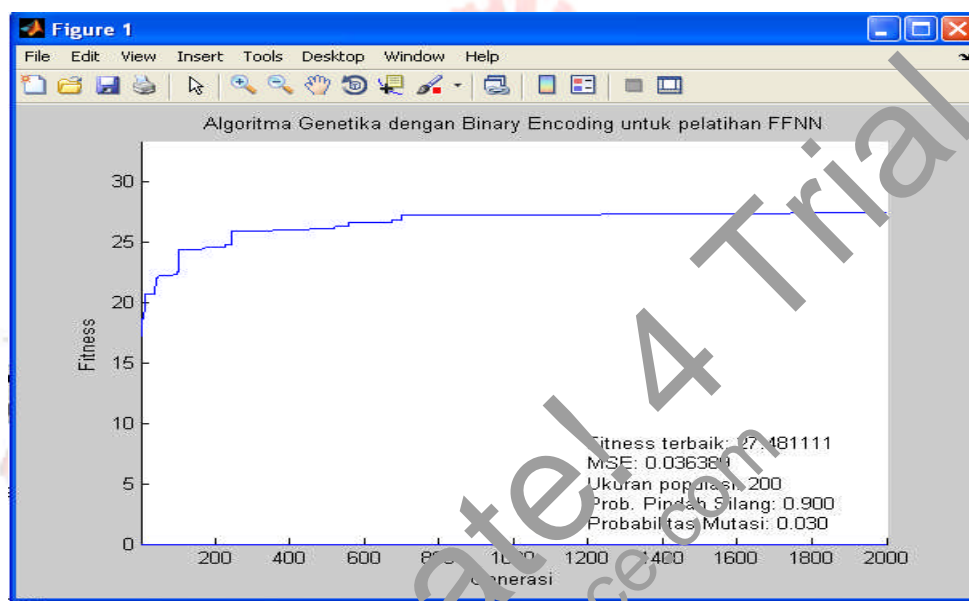
Tabel 20. Hasil prediksi metode NN, contoh: temperatur pada bulan Maret

Tgl	Pelatihan dan Pengujian Temperatur Bulan Maret			
	Real 2009 (°C)	Prediksi 2009 (°C)	Real 2010 (°C)	Prediksi 2010 (°C)
1	26,3000	26,3068	28.7	28,0361
2	27,8000	27,9281	28.7	27,6822
3	26,0000	25,9846	28.9	28,0531
4	26,8000	26,7954	28.4	27,8773
5	27,1000	27,1093	28	28,0425
6	27,1000	27,9587	28.3	28,3187
7	27,7000	27,1944	29	27,8655
8	27,3000	27,2530	27.1	27,2295
9	26,3000	26,3279	27.3	27,5431
10	25,7000	25,4396	27.2	27,8882
11	25,3000	25,5845	27	28,2942
12	26,7000	26,5498	27.8	26,9565
13	25,9000	25,8815	27.8	28,3652
14	26,0000	28,6635	28.2	28,3601
15	27,4000	27,3555	27.3	28,2616
16	26,7000	26,6793	28.3	27,0994
17	27,3000	26,8924	28.7	27,6141
18	28,2000	28,2495	27.4	27,9206
19	26,9000	26,7373	28.2	27,0098
20	27,8000	27,2974	27.2	28,1553
21	27,7000	27,0014	28.3	27,0853
22	27,5000	28,0792	27.7	27,6530
23	27,8000	27,5899	27.2	28,5201
24	28,1000	28,1425	28.1	28,4752
25	26,9000	26,9081	28.4	27,8118
26	26,9000	26,8876	28.4	27,1356
27	27,6000	27,6689	28.1	27,7486
28	26,9000	27,5666	26.7	26,9684
29	27,8000	27,8039	26.9	25,7385
30	28,4000	28,3254	26.6	27,4008
31	28,1000	28,4243	25.2	27,5126

Tabel 21. Hasil prediksi metode NN untuk variabel input tahun 2009 dan 2010

Tgl	Kecepatan Angin (knot)		Kelembaban (%)		Temperatur (° Celcius)	
	2009	2010	2009	2010	2009	2010
1	18	13	99	64	28,9464	27,0335
2	15	14	94	64	29,0221	24,6939
3	19	15	83	64	29,1279	23,5459
4	22	22	95	64	23,8279	24,1295
5	19	29	86	98	26,6951	24,2681
6	14	22	96	96	25,0400	23,2636
7	20	17	98	91	24,0661	26,6251
8	20	14	83	93	26,9988	26,0990
9	25	20	87	84	25,2732	29,2134
10	15	23	90	97	25,9678	27,4974
11	14	19	83	87	25,0380	29,0211
12	23	27	83	93	24,7691	27,4207
13	28	16	99	95	25,0559	25,3812
14	18	15	90	98	25,0268	25,9686
15	28	28	95	99	24,0989	29,0614
16	24	22	98	64	24,8863	28,0116
17	22	16	97	89	26,0725	29,1858
18	13	16	90	95	27,0447	24,7904
19	17	21	83	98	23,5211	25,9578
20	25	17	83	95	25,3280	25,4301
21	14	15	86	95	24,1791	23,6196
22	14	18	97	83	24,3188	24,9677
23	14	19	99	66	24,7643	24,3496
24	14	17	96	68	25,8998	25,4155
25	15	24	98	85	25,6676	23,6723
26	15	18	99	82	23,8081	27,1978
27	15	26	98	66	24,3721	24,0906
28	14	19	97	98	23,5579	26,6246
29	16	16	97	94	24,6076	24,4254
30	21	14	92	68	27,4275	23,1554
31	26	20	98	92	28,5193	25,1953

Selanjutnya GA akan mencari nilai bobot dan bias yang paling optimal yang diletakkan di dalam *function* Binary EvalInd agar dengan bobot dan bias tersebut jaringan menghasilkan nilai MSE yang paling kecil.

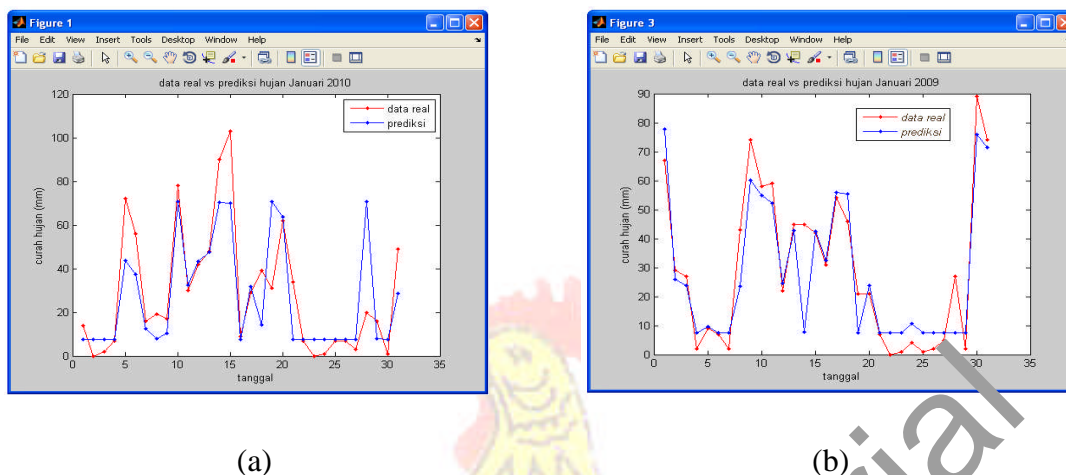


Gambar 55. Grafik pergerakan nilai *fitness* prediksi curah hujan bulan Januari 2009

Pada Gambar 54 dapat dilihat perubahan nilai MSE jaringan berdasarkan nilai *fitness* yang dihasilkan oleh GA, dimana $MSE = 1/fitness$. Nilai *fitness* awal sebesar 18.6999456 dengan MSE sebesar 0.0534761 dan setelah dilakukan optimasi dengan GA maka nilai *fitness* meningkat menjadi 27.481111 dengan MSE sebesar 0.036389. Meningkatnya nilai *fitness* menyebabkan nilai MSE semakin kecil yang menandakan bahwa *error* antara output jaringan dengan target semakin kecil. Kemudian GA akan menghasilkan prediksi curah hujan seperti pada tabel 19.

Tabel 22. Hasil prediksi curah hujan menggunakan metode GA-NN, Contoh:
Curah hujan bulan Januari 2009

Tanggal	Januari 2009		Januari 2010	
	Prediksi (mm)	Aktual (mm)	Prediksi (mm)	Aktual (mm)
1	77,80	67	7,67	14
2	26,03	29	7,67	0
3	23,87	27	7,67	2
4	7,46	2	7,67	7
5	9,51	9	43,77	32
6	7,46	7	37,35	56
7	7,46	2	12,58	16
8	23,58	43	7,97	19
9	60,19	74	10,23	17
10	54,74	58	70,55	78
11	52,27	59	32,61	30
12	24,55	22	43,38	42
13	42,63	45	47,67	48
14	7,80	45	70,37	90
15	42,63	42	69,98	103
16	32,56	31	7,67	9
17	75,86	54	31,60	29
18	35,37	46	14,29	39
19	7,46	21	70,75	31
20	23,76	21	63,70	62
21	7,50	7	7,70	34
22	7,46	0	7,67	7
23	7,46	1	7,67	0
24	10,62	4	7,67	1
25	7,52	1	7,67	7
26	7,46	2	7,68	7
27	7,46	5	7,67	3
28	7,46	27	70,79	20
29	7,46	2	7,79	16
30	76,05	89	7,67	1
31	71,57	74	28,75	49



Gambar 56. Metode GA-NN dengan data real (a) Januari 2009 ; (b) Januari 2010

- RMSE *Genetic Algorithm – Neural Network*

$$RMSE = \frac{\sqrt{\sum_{t=h}^M (y_t - \hat{y}_t)^2}}{y_{\max} - y_{\min}}$$

$$= 0,0092$$

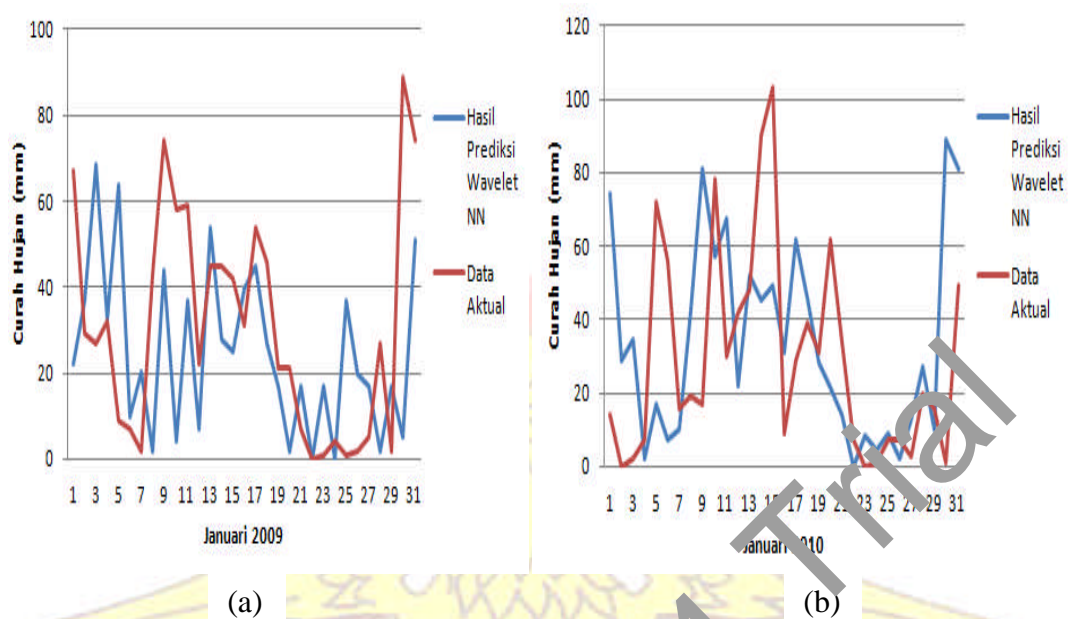
Dan persentase keakuratan sebesar 85.2%,

4. *Wavelet - Neural Network*

Proses prediksi ini menggunakan metode *neural network back propagation* karena metode *back propagation* sangat cocok untuk prediksi data. *Back propagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan. Tabel berikut merupakan hasil prediksi curah hujan bulan Januari tahun 2009 yang hanya menggunakan metode *neural network*.

Tabel 23. Hasil prediksi curah hujan menggunakan metode *Wavelet Neural Network* bulan Januari 2009 dan 2010

Tanggal	Januari 2009		Januari 2010	
	Prediksi (mm)	Aktual (mm)	Prediksi (mm)	Aktual (mm)
1	22,05	67	74,24	14
2	36,62	29	28,99	0
3	68,65	27	34,64	2
4	32,65	32	2,12	7
5	63,78	9	16,97	72
6	9,83	7	7,07	56
7	20,12	2	9,89	16
8	1,98	43	4,42	19
9	43,92	74	81,3	17
10	4,01	58	57,27	78
11	36,98	59	67,17	30
12	6,97	22	21,92	42
13	53,79	45	52,32	48
14	27,71	45	45,25	90
15	25,02	42	49,49	103
16	39,58	31	31,11	9
17	44,87	54	61,51	29
18	26,73	46	45,96	39
19	17,15	21	28,28	31
20	1,98	21	21,21	62
21	17,16	7	14,14	34
22	0	0	0	7
23	17,15	1	8,48	0
24	0	4	4,24	1
25	36,96	1	9,19	7
26	19,79	2	2,12	7
27	17,15	5	12,72	3
28	1,98	27	26,87	20
29	17,14	2	9,89	16
30	5,01	89	89,09	1
31	50,80	74	81,31	49



Gambar 57. Grafik perbandingan hasil prediksi curah hujan menggunakan metode *Wavelet NN* dengan data aktual, (a) Januari 2009; (b) Januari 2010

➤ RMSE *Wavelet Neural Network*

$$RMSE = \frac{\sqrt{\frac{1}{N} \sum_{t=h}^N (y_t - \hat{y}_t)^2}}{y_{\max} - y_{\min}}$$

= 0,3219

Dan persentase keakuratan sebesar 73,97%

D. Hasil Prediksi Curah Hujan Tahunan Metode Kualitatif

1. ANFIS (*Adaptive Neuro Fuzzy Interference System*)

Pada perancangan prediksi Curah Hujan dengan menggunakan metode ANFIS, terlebih dahulu ditentukan variabel input *checking* dengan menggunakan *neural network*. Variabel input *checking* terhadap ketiga variabel input terpilih yaitu Temperatur, Kelembaban dan Kecepatan Angin yang akan diprediksi dengan metode *neural network* kemudian akan dijadikan input *checking* pada metode ANFIS untuk mendapatkan curah hujan, setelah itu dilakukan pencocokan data guna menghitung keakuratan sistem.

Tabel berikut adalah salah satu contoh hasil prediksi menggunakan metode Neural Network untuk variabel Temperatur pada bulan Mei 2010. Tabel tersebut merupakan hasil pelatihan *neural network* temperatur pada bulan Mei 2010 yang dibandingkan dengan data observasi BMKG bulan Mei tahun 2010. Hasil pelatihan *neural network* ini mempunyai performansi (RMSE) sebesar 0.0048.

Tabel 24. Hasil prediksi temperatur bulan Mei tahun 2010

Tanggal	Prediksi (°C)	Aktual (°C)
---------	------------------	----------------

1	28.29	28.2
2	27.24	28.4
3	27.53	28.3
4	28.29	28
5	26.05	27.8
6	26.17	28.2
7	25.36	28
8	28.19	27.6
9	27.15	28.2
10	26.31	27.2
11	25.99	27.7
12	28.05	27.6
13	26.44	28.1
14	25.22	27.7
15	25.14	27.4
16	25.82	27.1
17	26.95	27.4
18	28.31	26.6
19	27.47	26.4
20	27.73	26.5
21	27.39	26.1
22	26.27	27.3
23	25.34	28.2
24	28.17	28.7
25	28.02	27.4
26	26.24	27
27	26.49	26.5
28	26.21	26.5
29	28.05	27.8
30	27.77	26.8

Tabel 25. Hasil prediksi curah hujan kualitatif menggunakan metode ANFIS bulan November Tahun 2009 dan 2010

Tgl	November 2009		November 2010	
	Prediksi	Aktual	Prediksi	Aktual

1	Cerah	Cerah	Cerah	Hujan Ringan
2	Cerah	Cerah	Cerah	Cerah
3	Cerah	Cerah	Cerah	Hujan Sedang
4	Cerah	Cerah	Cerah	Hujan Sedang
5	Cerah	Cerah	Cerah	Cerah
6	Cerah	Cerah	Cerah	Hujan Lebat
7	Cerah	Cerah	Cerah	Cerah
8	Cerah	Cerah	Cerah	Cerah
9	Cerah	Cerah	Cerah	Hujan Sedang
10	Cerah	Cerah	Cerah	Cerah
11	Cerah	Cerah	Cerah	Hujan Ringan
12	Hujan Sedang	Cerah	Cerah	Cerah
13	Hujan Sangat Lebat	Cerah	Cerah	Cerah
14	Cerah	Hujan Sedang	Cerah	Cerah
15	Hujan Ringan	Cerah	Cerah	Cerah
16	Hujan Ringan	Cerah	Cerah	Cerah
17	Hujan Ringan	Cerah	Cerah	Cerah
18	Hujan Ringan	Hujan Ringan	Cerah	Hujan Ringan
19	Cerah	Cerah	Hujan Ringan	Cerah
20	Cerah	Cerah	Hujan Ringan	Hujan Ringan
21	Hujan Ringan	Cerah	Cerah	Cerah
22	Cerah	Cerah	Hujan Ringan	Cerah
23	Cerah	Cerah	Hujan Ringan	Hujan Ringan
24	Cerah	Cerah	Cerah	Cerah
25	Cerah	Cerah	Cerah	Hujan Ringan
26	Hujan Ringan	Hujan Lebat	Hujan Sedang	Hujan Sedang
27	Hujan Ringan	Cerah	Cerah	Cerah
28	Hujan Ringan	Cerah	Cerah	Cerah
29	Cerah	Hujan Ringan	Cerah	Cerah
30	Hujan Sedang	Cerah	Cerah	Cerah

➤ Keakuratan Metode ANFIS

Untuk menghitung besarnya persentase keakuratan metode ini, terlebih dahulu memperhatikan tabel berikut:

Tabel 26. Validasi hasil prediksi hujan sistem ANFIS Observasi tahun 2009

No.	ANFIS	Cerah	Hujan			
			Ringan	Sedang	Lebat	Sangat Lebat
1	Observasi	278	39	31	15	2
2	Prediksi	226	93	38	3	4
Jumlah benar (hari)		238 hari				
Jumlah salah (hari)		127 hari				
Keakuratan (%)		65%				

$$\text{Keakuratan (\%)} = \frac{(365 - 127) \text{ hari}}{365 \text{ hari}} \times 100\%$$

$$= \frac{238 \text{ hari}}{365 \text{ hari}} \times 100\%$$

$$= 65 \%$$

Tabel 27. Validasi hasil prediksi hujan sistem ANFIS dan aktual tahun 2010

No.	ANFIS	Cerah	Hujan			
			Ringan	Sedang	Lebat	Sangat Lebat
1	Observasi	224	78	47	14	2
2	Prediksi	226	92	39	2	6
Jumlah benar (hari)		218 hari				
Jumlah salah (hari)		147 hari				
Keakuratan (%)		59.72%				

$$\text{Keakuratan (\%)} = \frac{(365 - 147) \text{ hari}}{365 \text{ hari}} \times 100\%$$

$$= \frac{218 \text{ hari}}{365 \text{ hari}} \times 100\%$$

Keakuratan (%) = 59.72%

2. *Neural Network - Fuzzy*

Untuk merancang prediksi Curah Hujan dengan sistem logika terlebih dahulu metode *neural network – Fuzzy logic* perlu dilakukan validasi dengan data aktual. Variabel input yaitu temperatur, kelembaban, dan kecepatan angin akan diprediksi dengan metode *neural network*(NN) dan kemudian akan dijadikan input pada metode *Fuzzy logic* untuk mendapatkan curah hujan, setelah itu dilakukan pencocokan data guna menghitung keakuratan sistem.

Tabel 25 merupakan contoh hasil pelatihan jaringan untuk prediksi temperatur bulan Mei 2010. Masing-masing pola dari variabel input yang diprediksi oleh *neural network* memiliki persentase yang berbeda-beda disebabkan pola data yang dipelajari oleh jaringan selama proses pelatihan.

Setelah mendapatkan pola yang terbaik dari proses pelatihan dan pengujian 2010 maka hasil prediksi tersebut akan digunakan sebagai input pada sistem *Fuzzy logic*.

Tabel 28. Hasil prediksi temperatur dengan metode NN bulan Mei 2010

Mei 2010			
Tx	Xtt	Prediksi	Aktual
28,2	28	27,2	28,5
28,4	28,1	27,6	28,6
28,3	27,8	27,1	27,9
28	28	27,5	27,9

27,8	27,5	27,3	28
28,2	28,1	27,2	26,7
28	27,8	28,2	27,8
27,6	27,8	27,2	27,3
28,2	28,1	27,6	27,6
27,2	27,3	28,1	26,8
27,7	27,6	27,5	27,1
27,6	27,6	28,1	28,1
28,1	26,9	27,2	28
27,7	27,6	27,2	26,6
27,4	27,5	27,6	28,5
27,1	27,7	27,1	28,1
27,4	26,9	27,2	27,3
26,8	27,2	28,3	28,1
26,4	26,8	27,9	28,9
26,5	26,7	27,9	28,6
26,1	27	28,1	27,3
27,3	27,1	27,2	27
28,2	28,1	28,3	28,5
28,7	27,9	27,9	28,3
27,4	27,7	27,7	28,9
27	27,1	28	29,1
26,5	27	27,6	27,9
26,5	27,5	28	28,3
27,6	27,6	27,5	27,7
26,8	26,9	27,5	27
28,7	28,2	27,4	27,3

Keterangan :

tx = Target 2009 xtt = Prediksi 2009

Proses perancangan prediksi hujan menggunakan metode *Fuzzy Takagi Sugeno* karena *Fuzzy Takagi Sugeno* bersifat konstan dan fleksibel sehingga cocok untuk peramalan. Pada proses fuzzifikasi data masukan berupa himpunan *crisp* yang akan diubah menjadi himpunan *Fuzzy* berdasarkan *range* untuk setiap variabel masukannya. Pada proses fuzzifikasi

ini terdapat dua hal yang harus diperhatikan yaitu nilai masukan dan nilai keluaran serta fungsi keanggotaan yang akan digunakan untuk menentukan nilai hasil keluaran *Fuzzy logic*. Pada proses fuzzifikasi perancangan prediksi metode *Fuzzy logic* menggunakan bentuk fungsi keanggotaan *gaussian* sebagai variabel masukan karena bentuk *gaussian Fuzzy sets* cocok untuk data-data alami seperti data cuaca.

Setelah dilakukan fuzzifikasi untuk setiap masukan dan keluaran, maka langkah berikutnya yaitu membuat aturan (*rule base*). *Rule base* ini terdiri dari kumpulan aturan peramalan cuaca yang berbasis *Fuzzy logic* untuk menyatakan kondisi cuaca yang terjadi. Penusunan *rule base* ini berdasarkan pada sistem pakar yang ada pada peramalan kondisi hujan terdapat tiga variabel masukan, satu variabel keluaran dan 36 *rule*. Variabel temperatur memiliki tiga fungsi keanggotaan untuk variabel masukan yaitu temperatur rendah, sedang, dan tinggi. Variabel kelembaban memiliki tiga fungsi keanggotaan yaitu kelembaban rendah, sedang, dan tinggi. Variabel angin memiliki empat fungsi keanggotaan yaitu ringan, sedang, kencang, dan sangat kencang.

Proses inferensi *Fuzzy* adalah proses pengambilan keputusan untuk mendapatkan himpunan *Fuzzy logic* berdasarkan rancangan *rule base*. Teknik pengambilan keputusan yang digunakan adalah teknik *Takagi Sugeno* karena metode ini lebih fleksibel sehingga cocok untuk peramalan. Teknik *Takagi Sugeno* dalam penerapannya menggunakan aturan operasi *AND*, hal ini dikarenakan semua aturan saling bergantung dan mempengaruhi. Setiap hasil dari *inference* sistem akan dikonversikan melalui tahap defuzzifikasi,

hasil konversi akan diekpresikan dalam bentuk *Fuzzy sets* kesatu bilangan *Real*. Dalam penelitian ini, metode defuzzifikasi yang digunakan adalah *weighted of average*.

Dalam pembuatan prediksi curah hujan maka salah satu tahun dari data BMKG akan digunakan untuk pengujian metode *Fuzzy logic* yaitu tahun 2009. Hasil prediksi *Fuzzy logic* tahun 2009 divalidasi dengan data aktual 2009 dari BMKG kemudian sistem *Fuzzy logic* ini akan digunakan untuk sistem prediksi dengan metode *neural network-Fuzzy logic*.

Tabel 29. Hasil *cluster* data rata-rata per hari tahun 2004 - 2008

Variabel Masukan	Klasifikasi	Nilai Min	Pusat Cluster	Nilai M1x	Standar Deviasi
Temperatur (°C)	Rendah	20.5	25.24	26	1.248
	Sedang	26.1	26.89	27.5	
	Tinggi	27.6	28.29	39	
Kelembaban (%)	Rendah	44	63.69	71	10.547
	Sedang	72	78.57	84	
	Tinggi	85	89.83	100	
Kecepatan Angin (knot)	Ringan	3	10.91	12	4.848
	Sedang	13	15.04	17	
	Kencang	18	19.05	22	
	Sangat Kencang	23	26.06	41	

Berikut akan diberikan tabel hasil prediksi curah hujan kuantitatif Metode NN *Fuzzy* untuk bulan November 2009 dan 2010.

Tabel 30. Hasil prediksi curah hujan kualitatif dengan metode NN *Fuzzy* untuk bulan November 2009 dan 2010

Tgl	November 2009		November 2010	
	Prediksi	Aktual	Prediksi	Aktual
1	Cerah	Cerah	Cerah	Hujan Ringan
2	Cerah	Cerah	Cerah	Cerah
3	Cerah	Cerah	Cerah	Hujan Sedang
4	Cerah	Cerah	Cerah	Hujan Sedang
5	Cerah	Cerah	Hujan Ringan	Cerah
6	Cerah	Cerah	Cerah	Hujan Lebat
7	Cerah	Cerah	Cerah	Cerah
8	Cerah	Cerah	Cerah	Cerah
9	Cerah	Cerah	Hujan Ringan	Hujan Sedang
10	Cerah	Cerah	Hujan Ringan	Cerah
11	Cerah	Cerah	Cerah	Hujan Ringan
12	Cerah	Cerah	Cerah	Cerah
13	Cerah	Cerah	Cerah	Cerah
14	Cerah	Hujan Sedang	Cerah	Cerah
15	Cerah	Cerah	Cerah	Cerah
16	Cerah	Cerah	Hujan Ringan	Cerah
17	Cerah	Cerah	Cerah	Cerah
18	Hujan Ringan	Hujan Ringan	Cerah	Hujan Ringan
19	Cerah	Cerah	Cerah	Cerah
20	Cerah	Cerah	Cerah	Hujan Ringan
21	Cerah	Cerah	Cerah	Cerah
22	Cerah	Cerah	Hujan Ringan	Cerah
23	Cerah	Cerah	Cerah	Hujan Ringan
24	Cerah	Cerah	Cerah	Cerah
25	Cerah	Cerah	Cerah	Hujan Ringan
26	Cerah	Hujan Lebat	Hujan Ringan	Hujan Sedang
27	Cerah	Cerah	Cerah	Cerah
28	Cerah	Cerah	Cerah	Cerah
29	Cerah	Hujan Ringan	Cerah	Cerah
30	Hujan Ringan	Cerah	Cerah	Cerah

Tabel 31. Validasi hasil prediksi hujan sistem *Fuzzy logic* dengan keadaan sebenarnya tahun 2009

No.	<i>Fuzzy logic</i>	Cerah	Hujan			
			Ringan	Sedang	Lebat	Sangat Lebat

1	Aktual	281	34	33	15	2
2	Prediksi	270	78	17	-	-
Jumlah benar (hari)	277 hari					
Jumlah salah (hari)	88 hari					
Keakuratan (%)	75.8%					

➤ Keakuratan Metode NN Fuzz

$$\begin{aligned} \text{Keakuratan (\%)} &= \frac{(365 - 65) \text{ hari}}{365 \text{ hari}} \times 100\% \\ &= \frac{277 \text{ hari}}{365 \text{ hari}} \times 100\% \end{aligned}$$

$$\text{Keakuratan (\%)} = 75,8\%$$

3. SVM (Support Vector Machine) - Fuzzy

Support Vector Machine digunakan untuk memprediksi variabel input yaitu temperatur, kelembaban, dan kecepatan maksimal angin yang akan diinput ke dalam *Fuzzy logic system*.

Nilai-nilai variable input diproses dengan *Support Vector Machine* setelah sebelumnya melalui proses *training*. Selanjutnya *Support Vector Machine* akan memproses data tersebut bersama dengan parameter-parameter pengendali *algoritma* yang telah ditentukan.

Support Vector Machine akan mencari set parameter berupa nilai bobot/*margin* dan bias (w, b) untuk menemukan fungsi pemisah (*classifier / hyperplane*) terbaik untuk memisahkan dua macam objek. Dimana, *Hyperplane* dikatakan terbaik jika terletak di tengah-tengah dua objek dari

kelas berbeda. *Hyperplane* terbaik juga apabila nilai *Lagrange Multiplier* (α) tidak sama dengan 0. Nilai α yang tidak sama dengan 0 itulah yang dikatakan sebagai *Support Vector*. Nilai α diperoleh dari proses *training* data. Setelah didapatkan nilai *Support Vector* dari seluruh data *training*, selanjutnya data *training* diproses kembali ke dalam tahap pemodelan klasifikasi dan selanjutnya menghasilkan nilai prediksi masing-masing variabel input. Sebagai contoh tabel 29 akan menyajikan hasil prediksi untuk variabel input yaitu temperatur dengan metode SVM.

Dengan cara yang sama dilakukan untuk variabel input lainnya (Kecepatan Angin dan Kelembaban) untuk prediksi tahun 2009 dan 2010. Dari hasil pelatihan dan prediksi bila dibandingkan dengan data aktual, maka terlihat perbedaan yang tidak signifikan, sehingga hasil prediksi ini menjadi input untuk sistem *Fuzzy Logic* untuk dilakukan pengambilan keputusan agar diperoleh nilai prediksi curah hujan untuk tahun 2009 dan tahun 2010.

Tabel 32. Perbandingan hasil prediksi parameter temperatur dengan metode *Support Vector Machine* dengan data aktual bulan November tahun 2009

Tgl	Prediksi Temperatur	Data Aktual Temperatur
1	27.9	28.5
2	28.5	28.7
3	28.4	30.1
4	30.1	29.8

5	28.8	30
6	30	30.4
7	30	30
8	29.7	30.2
9	30.4	29.7
10	29.5	29
11	29.3	30.6
12	31.2	29.4
13	28.7	27.8
14	28.4	28.6
15	29.3	29.2
16	29.1	28.4
17	28.4	27.9
18	28.2	26.7
19	26.7	28.6
20	29.4	29.1
21	28.4	25.5
22	28.3	29.4
23	29.4	28
24	27.1	28.6
25	29.5	28
26	27.7	26.2
27	26.6	27.9
28	29.1	28
29	27.4	27.6
30	27.7	26.5

Tabel 32 Hasil prediksi curah hujan kualitatif menggunakan metode SVM Fuzzy, bulan November tahun 2009 dan 2010

Tgl	November 2009		November 2010	
	Prediksi	Aktual	Prediksi	Aktual
1	Cerah	Cerah	Cerah	Hujan Ringan
2	Cerah	Cerah	Hujan Ringan	Cerah
3	Cerah	Cerah	Cerah	Hujan Sedang
4	Cerah	Cerah	Cerah	Hujan Sedang
5	Cerah	Cerah	Cerah	Cerah

6	Cerah	Cerah	Cerah	Hujan Lebat
7	Cerah	Cerah	Cerah	Cerah
8	Cerah	Cerah	Cerah	Cerah
9	Cerah	Cerah	Cerah	Hujan Sedang
10	Cerah	Cerah	Cerah	Cerah
11	Cerah	Cerah	Cerah	Hujan Ringan
12	Cerah	Cerah	Cerah	Cerah
13	Cerah	Cerah	Cerah	Cerah
14	Cerah	Hujan Sedang	Cerah	Cerah
15	Cerah	Cerah	Cerah	Cerah
16	Cerah	Cerah	Cerah	Cerah
17	Cerah	Cerah	Hujan Ringan	Cerah
18	Cerah	Hujan Ringan	Cerah	Hujan Ringan
19	Hujan Ringan	Cerah	Cerah	Cerah
20	Cerah	Cerah	Cerah	Hujan Ringan
21	Cerah	Cerah	Cerah	Cerah
22	Cerah	Cerah	Cerah	Cerah
23	Cerah	Cerah	Hujan Ringan	Hujan Ringan
24	Cerah	Cerah	Cerah	Cerah
25	Cerah	Cerah	Cerah	Hujan Ringan
26	Cerah	Hujan Lebat	Cerah	Hujan Sedang
27	Cerah	Cerah	Hujan Ringan	Cerah
28	Cerah	Cerah	Cerah	Cerah
29	Cerah	Hujan Ringan	Cerah	Cerah
30	Cerah	Cerah	Cerah	Cerah

Terlihat perbedaan akurasi prediksi pada tahun 2009 dan 2010, ini disebabkan karena pada tahun 2010 terjadi La Nina dimana hujan terjadi sepanjang tahun. Sedangkan data yang digunakan untuk pelatihan 2004-2009 tidak menunjukkan gejala La Nina. Sebagai akibatnya, prediksi 2010 mengalami penurunan drastis.

- Keakuratan Metode SVM Fuzzy

Sebagaimana halnya dengan kedua metode *hybrid* sebelumnya yaitu ANFIS dan JST-*Fuzzy*, keakuratan system kualitatif ditinjau menjadi 6 cluster keadaan hujan yaitu cerah, ringan, sedang, lebat dan sangat lebat.

Nilai-nilai variabel input diproses dengan *Support Vector Machine* setelah sebelumnya melalui proses *training*. Selanjutnya *Support Vector Machine* akan memproses data tersebut bersama dengan parameter-parameter pengendali *algoritma* yang telah ditentukan.

Support Vector Machine akan mencari set parameter berupa nilai bobot/*margin* dan bias (w, b) untuk menemukan fungsi pemisah (*classifier/hyperplane*) terbaik untuk memisahkan dua macam objek. Dimana, *Hyperplane* dikatakan terbaik jika terletak di tengah-tengah dua objek dari kelas berbeda. *Hyperplane* terbaik juga apabila nilai *Lagrange Multiplier* (α) tidak sama dengan 0. Nilai α yang tidak sama dengan 0 itulah yang dikatakan sebagai *Support Vector*. Nilai α diperoleh dari proses *training* data. Setelah didapatkan nilai *Support Vector* dari seluruh data *training*, selanjutnya data *training* diproses kembali kedalam tahap pemodelan klasifikasi dan selanjutnya menghasilkan nilai prediksi masing-masing parameter.

Tabel.34. Keakuratan prediksi dengan metode *Support Vector Machine-Fuzzy Logic* tahun 2009

Bulan	Data	Banyak Data					Jumlah Prediksi		Keakuratan (%)
		Cerah	Hujan				Benar (hari)	Salah (hari)	
			Ringan	Sedang	Lebat	Sangat Lebat			
Januari	Aktual	9	3	12	7	0	17	14	

	Prediksi	10	11	9	1	0			
Februari	Aktual	10	7	6	3	2	21	7	
	Prediksi	9	11	6	2	0			
Maret	Aktual	25	4	2	0	0	24	7	
	Prediksi	22	9	0	0	0			
April	Aktual	22	5	3	0	0	25	5	
	Prediksi	23	7	0	0	0			
Mei	Aktual	23	5	3	0	0	24	7	
	Prediksi	27	4	0	0	0			
Juni	Aktual	29	0	1	0	0	29	1	
	Prediksi	30	0	0	0	0			
Juli	Aktual	29	2	0	0	0	25	6	
	Prediksi	26	5	0	0	0			
Agustus	Aktual	31	0	0	0	0	31	0	
	Prediksi	31	0	0	0	0			
September	Aktual	27	1	2	0	0	27	3	
	Prediksi	30	0	0	0	0			
Oktober	Aktual	29	1	1	0	0	29	2	
	Prediksi	29	2	0	0	0			
November	Aktual	26	2	1	1	0	24	6	
	Prediksi	29	0	0	0	0			
Desember	Aktual	18	7	2	4	0	15	16	
	Prediksi	14	14	3	0	0			
Tahun 2009							291	74	80

Kekuatan prediksi Support Vector Machine-Fuzzy Logic adalah

sebagai berikut:

$$(\%) = \frac{80}{291} \times 100\% = 80\%$$

E. Perbandingan Hasil Prediksi Metode Kuantitatif

1. Analisis Trend

Perbandingan hasil prediksi 4 metode kuantitatif yang digunakan serta data aktual dari BMKG untuk contoh curah hujan bulan januari 2009 diberikan pada tabel 32. Sementara perbandingan untuk tahun 2010 disajikan pada tabel 33. Pemilihan bulan januari sebagai perbandingan karena pada bulan januari merupakan puncak periode hujan untuk kota Makassar sesuai kategori C. Keempat sistem prediksi yang akan dibandingkan adalah GA-NN, Wavelet-NN, ASTAR dan ARIMA. Nilai yang dibandingkan adalah kuantitas hujan harian selama bulan januari dari prediksi terhadap data aktual.

Syarat suatu system prediksi dinyatakan lebih baik dari lainnya ditinjau dari seberapa kecil RMSE yang diperoleh serta tren pola prediksi terhadap aktual yang paling sesuai.

Terlihat pada tabel perbandingan di bawah ini, ASTAR mengungguli sistem lainnya dengan tren yang paling sesuai antara prediksi dan aktual.

Tabel 35. Perbandingan hasil prediksi curah hujan metode kuantitatif bulan Januari 2009


Tanggal	Hasil Prediksi				Data Aktual (mm)
	GA-NN (mm)	Wavelet NN (mm)	ASTAR (mm)	ARIMA (mm)	
1	77.80	22.05	67.2	14.86	67
2	26.03	36.62	28.9	17.14	29
3	23.87	68.65	33.3	36.3	27
4	7.46	32.65	6.8	20.87	2
5	9.51	63.78	12.7	7.48	9
6	7.46	9.83	15.6	3.42	7
7	7.46	20.12	3.8	8.23	2
8	23.58	1.98	39.2	8.96	43
9	60.19	43.92	76.1	67.25	74

10	54.74	4.01	58.4	55.22	58
11	52.27	36.98	39.2	51.45	59
12	24.55	6.97	24.5	35.3	22
13	42.63	53.79	46.6	11.6	45
14	7.80	27.71	46.6	33.01	45
15	42.63	25.02	42.2	22.65	42
16	32.56	39.58	31.8	27.2	31
17	55.86	44.87	52.5	30.09	54
18	55.37	26.73	46.6	42.49	46
19	7.46	17.15	18.6	20.22	21
20	23.76	1.98	20.0	40.45	21
21	7.50	17.16	8.2	0	7
22	7.46	0	0.9	10.13	0
23	7.46	17.15	2.4	3.83	1
24	10.62	0	6.8	29.9	4
25	7.52	36.96	0.6	15.04	1
26	7.46	19.79	0.9	0	2
27	7.46	17.15	3.3	0	5
28	7.46	1.98	29.9	4.04	27
29	7.46	17.14	2.4	8.8	2
30	76.05	5.91	90.8	81.98	89
31	71.57	50.80	76.1	71.35	74


Tabel 36. Perbandingan hasil prediksi curah hujan metode kuantitatif bulan Januari 2010

Tanggal	Hasil Prediksi				Data Aktual (mm)
	GA-NN (mm)	Wavelet NN (mm)	ASTAR (mm)	ARIMA (mm)	
1	7.67	74.24	13.1	46.81	14
2	7.67	28.99	3.6	20.94	0
3	7.67	34.64	3.2	43.80	2
4	7.67	2.12	13.1	16.91	7
5	43.77	16.97	62.4	22.39	72
6	37.39	7.07	44.5	21.73	56
7	12.58	9.89	14.4	4.38	16
8	7.97	42.42	12.8	21.08	19


9	10.28	81.31	23.2	31.78	17
10	70.55	57.27	66.5	39.26	78
11	32.61	67.17	33.4	8.42	30
12	43.38	21.92	37.9	13.23	42
13	47.67	52.32	43.1	15.62	48
14	70.37	45.25	60.5	62.91	90
15	69.98	49.49	66.2	24.71	103
16	7.67	31.11	8.7	33.14	9
17	31.60	61.51	33.5	22.59	29
18	14.29	45.96	31.4	33.35	39
19	70.75	28.28	31.2	16.04	31
20	63.70	21.21	63.5	21.19	62
21	7.70	14.14	33.6	0	34
22	7.67	0	40.2	11.27	7
23	7.67	8.48	8.9	3.72	0
24	7.67	4.24	0.3	15.02	1
25	7.67	9.19	14.4	31.56	7
26	7.68	2.12	5.5	0	7
27	7.67	12.72	8.0	0	3
28	70.79	26.87	27.7	54.55	20
29	7.79	9.89	19.8	7.48	16
30	7.67	81.09	3.4	37.35	110
31	28.75	81.31	46.9	183.32	49




Gambar 58. Grafik perbedaan hasil prediksi metode kuantitatif Januari 2009



Gambar 59. Grafik perbedaan hasil prediksi metode kuantitatif Januari 2010



Gambar 60. Grafik perbandingan metode kuantitatif tahun 2009



Gambar 61. Grafik perbandingan metode kuantitatif tahun 2010

Dari Grafik di atas terlihat jelas, diantara keempat metode kuantitatif, yang paling mendekati nilai aktual adalah metode ASTAR, karena memiliki *trend* yang hampir sama dengan data aktual. Sementara yang paling jauh simpangan prediksinya terhadap nilai aktual adalah metode Wavelet NN.

2. Persentase Keakuratan

Besar nilai RSME masing-masing metode prediksi untuk metode kuantitatif disajikan pada tabel berikut:

Tabel 37. Perbandingan nilai RMSE

Jenis Metode Prediksi	RSME
<i>Genetic Algorithm – Neural Network</i>	0,0921
<i>Wavelet Neural Network</i>	0,3219
ASTAR	0,0243
ARIMA	0,2392

Terlihat ASTAR memberikan hasil prediksi terbaik baik dari sisi pola tren actual terhadap prediksi maupun dari nilai RMSE yang terkecil. Kecerdasan buatan *hybrid* diungguli oleh GA-NN dibandingkan dengan *wavelet-NN* yang tidak memberikan performansi sesuai diharapkan. *Wavelet* selama ini digunakan untuk transformasi gambar, hal inilah yang menyebabkan kegagalan dalam melihat data skalar.

F. Perbandingan Hasil Prediksi Metode Kualitatif

1. Analisis *Trend*

Berdasarkan nilai curah hujan data aktual dari BMKG dan nilai curah hujan hasil prediksi dengan berbagai metode kualitatif yang telah diuraikan pada bagian sebelumnya, maka perbandingan hasil dapat diuraikan pada tabel berikut dengan sebelumnya melakukan konversi kategori, yaitu:

- Kategori 1 untuk kondisi cerah
- Kategori 2 untuk kondisi hujan ringan
- Kategori 3 untuk kondisi hujan sedang
- Kategori 4 untuk kondisi hujan lebat
- Kategori 5 untuk kondisi hujan sangat lebat


Dari periode bulan hujan oktober-maret, bulan nopember memberikan ciri yang lebih kontras secara kualitatif untuk pola tren. Untuk itu pola tren ditunjukkan menggunakan bulan november.

Tabel 38. Perbandingan hasil prediksi curah hujan metode kualitatif bulan November 2009


Tanggal	Hasil Prediksi			Data Aktual
	ANFIS	NN Fuzzy	SVM Fuzzy	
1	1	1	1	1
2	1	1	1	1
3	1	1	1	1
4	1	1	1	1
5	1	1	1	1
6	1	1	1	1
7	1	1	1	1
8	1	1	1	1
9	1	1	1	1
10	1	1	1	1
11	1	1	1	1
12	3	1	1	1
13	5	1	1	1
14	1	1	1	2
15	2	1	1	1
16	2	1	1	1
17	2	1	1	1
18	2	2	1	2
19	1	1	2	1
20	1	1	1	1
21	2	1	1	1
22	1	1	1	1
23	1	1	1	1
24	1	1	1	1
25	1	1	1	1
26	2	1	1	4
27	2	1	1	1
28	2	1	1	1
29	1	1	1	2
30	2	2	1	1

Tabel 39. Perbandingan hasil prediksi curah hujan metode kualitatif bulan November 2010


Tanggal	Hasil Prediksi			Data Aktual
	ANFIS	NN Fuzzy	SVM Fuzzy	
1	1	1	1	2
2	1	1	2	1
3	1	1	1	3
4	1	1	1	3
5	1	2	1	1
6	1	1	1	4
7	1	1	1	1
8	1	1	1	1
9	1	2	1	3
10	1	2	1	1
11	1	1	1	2
12	1	1	1	1
13	1	1	1	1
14	1	1	1	1
15	1	1	1	1
16	1	2	1	1
17	1	1	2	1
18	1	1	1	2
19	2	1	1	1
20	2	1	1	2
21	1	1	1	1
22	2	2	1	1
23	2	1	2	2
24	1	1	1	1
25	1	1	1	2
26	2	2	1	3
27	1	1	2	1
28	1	1	1	1
29	1	1	1	1
30	1	1	1	1




Gambar 62. Grafik perbedaan hasil prediksi metode kualitatif November 2009



Gambar 63. Grafik perbedaan hasil prediksi metode kualitatif November 2010



Gambar 64. Grafik perbandingan metode kualitatif tahun 2009



Gambar 65. Grafik perbandingan metode kualitatif tahun 2010

Terlihat pada gambar di atas bahwa SVM-Fuzzy memiliki pola tren prediksi aktual yang paling baik. Hal ini terutama cukup terlihat pada pengamatan tahun 2009 dimana kedua sistem prediksi lainnya terutama ANFIS terlihat cukup menyimpang dari data aktual.

Kegagalan SVM-*Fuzzy* yang cukup kontras hanya terletak pada tanggal 26 Nopember dimana ANFIS malah memberikan prediksi yang lebih dekat dari aktual.

Dari kedua Grafik di atas, tampak bahwa kesamaan *trend* terhadap data aktual dimiliki oleh metode SVM *Fuzzy* dan NN *Fuzzy* sementara metode ANFIS memiliki *trend* yang cenderung jauh dari nilai aktual baik untuk data tahun 2009 maupun 2010.

2. Persentase Keakuratan

Besar tingkat keakuratan untuk masing-masing metode prediksi untuk metode kualitatif disajikan pada tabel berikut

Tabel 40. Perbandingan nilai % keakuratan tahun 2009

Jenis Metode Prediksi	% Keakuratan
ANFIS	65
Neural Network – <i>Fuzzy</i>	75,8
Support Vector Machine – <i>Fuzzy</i>	80

Dapat terlihat metode NN-*Fuzzy* dan SVM-*Fuzzy* lebih mampu beradaptasi terhadap ketidakstasioneran data. Sehingga pengembangan ke depan akan lebih ditekankan pada validitas dan resolusi data primer yang cukup untuk meningkatkan tingkat prediksi.

G. Parameter Terbaik Untuk Sistem Prediksi pada Kuantitatif dan Kualitatif

Sesuai dengan hasil perbandingan prediksi kuantitatif maka sistem terbaik untuk kota Makassar adalah menggunakan metode ASTAR. Dengan persamaan model untuk tahun 2009 yang diperoleh dari simulasi adalah:

$$Y = |-9.296 + 36.493 * BF_2 + 5.351 * BF_4 + 1.302 * BF_5|$$

Dengan,

$$BF_2 = \max(0, 24.200 - \text{Temperatur});$$

$$BF_4 = \max(0, 12.000 - \text{Angin}_1);$$

$$BF_5 = \max(0, \text{Kelembaban} - 69.000);$$

$$\text{Model Hujan}_{FE} = BF_2 * BF_4 * BF_5$$

dan untuk prediksi Tahun 2010, model persamaan:

$$Y = |-12.294 + 32.570 * BF_2 + 4.995 * BF_4 + 1.493 * BF_5|$$


Dengan,

$$BF_2 = \max(0, 24.3 - \text{Temperatur});$$

$$BF_4 = \max(0, 12 - \text{Angin});$$

$$BF_5 = \max(0, \text{Kelembaban} - 69)$$

$$\text{Model Hujan } Y = BF_2 * BF_4 * BF_5$$



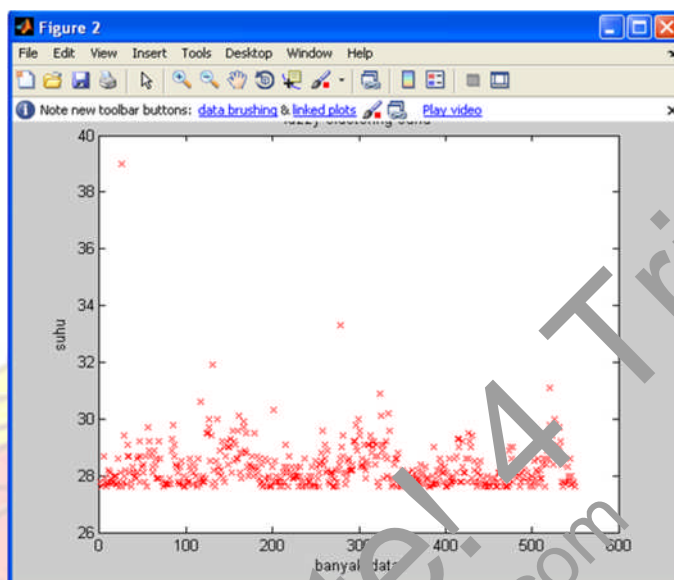
Gambar 67. *Cluster 2* temperatur sedang

Data yang diperoleh *cluster 1* (temperatur rendah) adalah nilai minimum= 20.5°C; *center*= 25.24°C; maksimum= 26°C. Hasil pengelompokan data yang tergabung dalam *cluster 1* bersifat menyebar dan banyak terdistribusi pada *range* (23 – 26)°C, seperti terlihat pada gambar 65.

Data yang diperoleh *cluster 2* (temperatur sedang) adalah minimum= 26.1°C; *center* = 26.89°C; maksimum= 27.5°C. Hasil pengelompokan data yang tergabung dalam *cluster 2* bersifat mengelompok pada layer tertentu dengan pola penyebaran merata pada *range* (26.1 – 27.5)°C. seperti terlihat pada gambar 66.

Data yang diperoleh *cluster 3* (temperatur tinggi) adalah nilai minimum= 27.6°C; *center*= 28.29°C; maksimum= 39°C. Hasil pengelompokan data yang tergabung dalam *cluster 3* bersifat menyebar

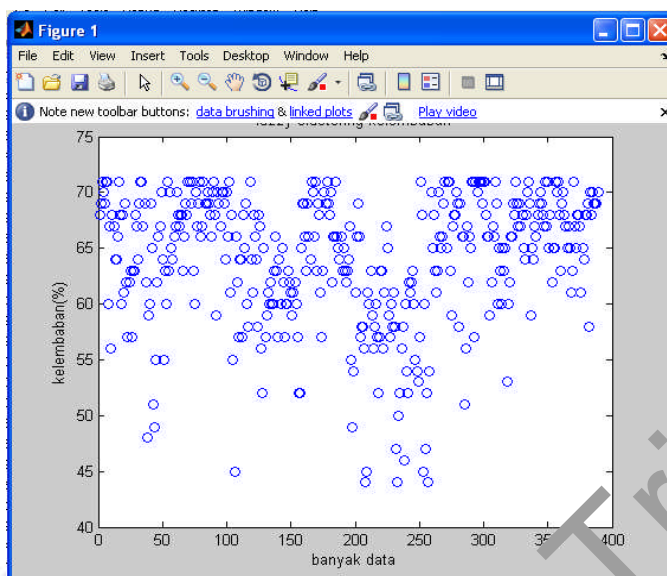
dan banyak terdistribusi pada *range* (27.6 – 31)°C seperti terlihat pada Gambar 67. Standar deviasi dari data temperatur adalah 1.248.



Gambar 68. *Cluster* 3 temperatur tinggi

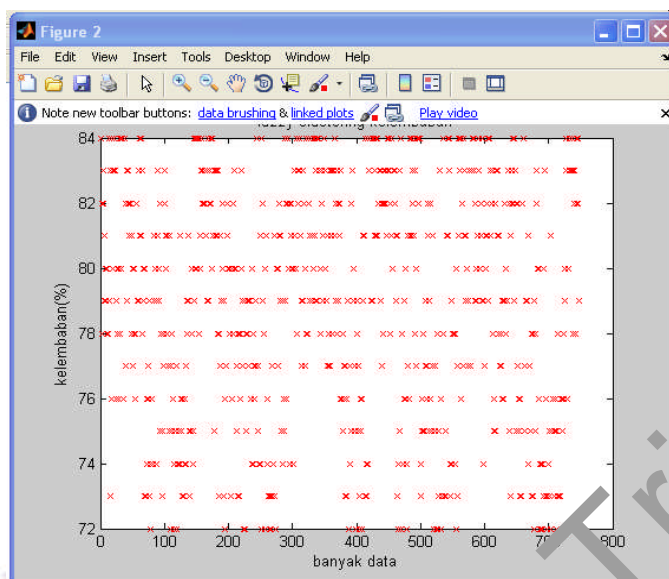
b) Kelembaban

Pembagian kelompok untuk variabel kelembaban dibagi dalam 3 *cluster*, yaitu *cluster* 1 digolongkan pada kelembaban rendah, *cluster* 2 digolongkan pada kelembaban sedang dan *cluster* 3 digolongkan pada kelembaban tinggi.



Gambar 69. Cluster 1 kelembaban rendah

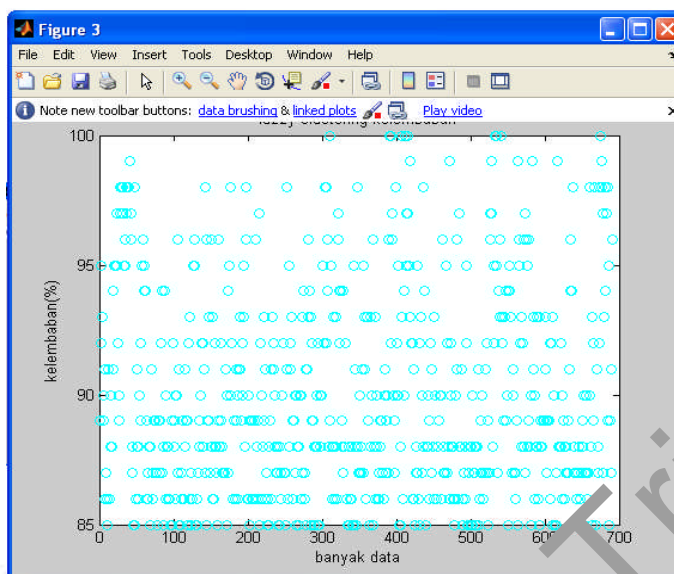
Data yang diperoleh cluster 1 (kelembaban rendah) adalah nilai minimum= 44%; center= 63.69%; maksimum= 71%. Hasil pengelompokan data yang tergabung dalam cluster bersifat menyebar dan banyak terdistribusi pada range (44 – 71)%. Seperti terlihat pada gambar 68.



Gambar 70. *Cluster 2* kelembaban sedang

Data yang diperoleh *cluster 2* (kelembaban sedang) adalah nilai minimum= 72%; *center*= 78.57%; maksimum= 84%. Hasil pengelompokan data yang tergabung dalam *cluster ke 2* bersifat mengelompok pada layer tertentu dengan pola penyebaran merata pada *range* (72 – 84)%, seperti terlihat pada gambar 69.

Data yang diperoleh *cluster 3* (kelembaban tinggi) adalah nilai minimum= 85%; *center*= 89.83%; maksimum= 100%. Hasil pengelompokan data yang tergabung dalam *cluster 3* bersifat mengelompok pada layer tertentu dengan pola penyebaran merata pada *range* (85 – 100)% seperti terlihat pada gambar 70. Standar deviasi dari data kelembaban adalah 10.547.




Gambar 71. *Cluster 3* kelembaban tinggi


c) Kecepatan angin

Pembagian kelompok untuk variabel angin dibagi dalam 3 *cluster* yaitu *cluster 1* digolongkan pada angin berkecepatan ringan, *cluster 2* digolongkan pada angin berkecepatan sedang, *cluster 3* digolongkan pada angin berkecepatan kencang, dan *cluster 4* digolongkan pada angin berkecepatan sangat kencang.

Data yang diperoleh *cluster 1* (kecepatan angin ringan) adalah nilai minimum= 3 knot; *center*= 10,91 knot; maksimum= 12 knot. Hasil pengelompokan data yang tergabung dalam *cluster 1* bersifat menyebar dan banyak terdistribusi pada *range* (6 – 12) knot seperti terlihat pada gambar 71.



Gambar 72. Cluster 1 kecepatan angin ringan

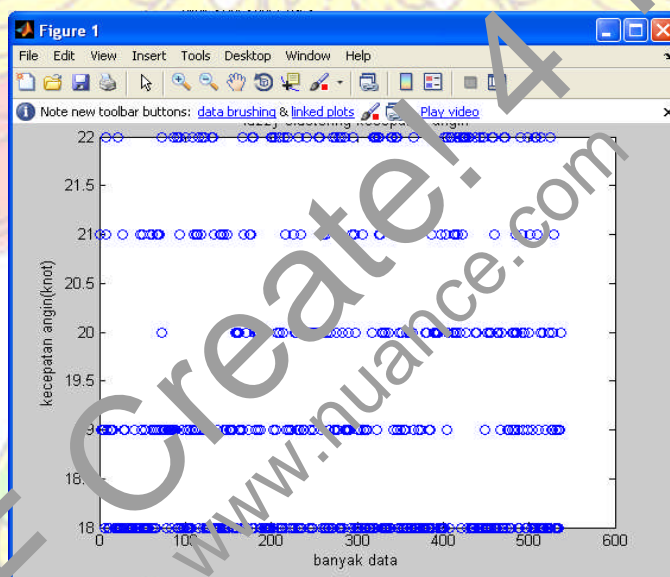


Gambar 73. Cluster 2 kecepatan angin sedang

Data yang diperoleh *cluster 2* (kecepatan angin sedang) adalah nilai minimum= 13 knot; *center*= 15.04 knot; maksimum= 17 knot. Hasil pengelompokan data yang tergabung dalam *cluster 2* bersifat mengelompok


pada layer tertentu dengan pola penyebaran merata seperti terlihat pada gambar 72.

Data yang diperoleh *cluster* 3 (kecepatan angin kencang) adalah nilai minimum= 18 knot; *center*= 19,05 knot; maksimum= 22 knot. Hasil pengelompokan data yang tergabung dalam *cluster* 3 bersifat mengelompok pada layer tertentu dengan pola penyebaran merata seperti terlihat pada gambar 73.



Gambar 74. *Cluster* 3 kecepatan angin kencang

Data yang diperoleh *cluster* 4 (kecepatan angin sangat kencang) adalah nilai minimum= 23 knot; *center* = 26.06 knot; maksimum= 41 knot. Hasil pengelompokan data yang tergabung dalam *cluster* 4 bersifat menyebar dan banyak terdistribusi pada *range* (23 – 36) knot seperti terlihat pada gambar 74. Standar deviasi dari data kecepatan angin adalah 4.848.



Gambar 75. Cluster 4 kecepatan angin sangat kencang


Tabel 41. Hasil cluster data rata-rata per hari tahun 2004 - 2008

Variabel Masukan	Klasifikasi	Nilai Min	Pusat Cluster	Nilai M1x	Standar Deviasi
Temperatur (°C)	Rendah	20.5	25.24	26	1.248
	Sedang	26.1	26.89	27.5	
	Tinggi	27.6	28.29	39	
Kelembaban (%)	Rendah	44	63.69	71	10.547
	Sedang	72	78.57	84	
	Tinggi	85	89.83	100	
Kecepatan Angin (knot)	Ringan	3	10.91	12	4.848
	Sedang	13	15.04	17	
	Kencang	18	19.05	22	
	Sangat Kencang	23	26.06	41	

H. Potensi Penelitian Selanjutnya


Dalam disertasi ini menggunakan data BMKG dengan resolusi sampling 1 hari. Begitu pula dengan penelitian-penelitian sebelumnya yang banyak menggunakan data sampling 1 hari. Hasil pengamatan sementara Radar LAPAN-Teknik Sipil Unhas untuk tahun 2012 menunjukkan adanya hubungan korelasi unsur meteorology terhadap curah hujan dengan sampling resolusi yang lebih rendah yaitu 8-12 jam.

Salah satu contoh hubungan unsur meteorologi terhadap curah hujan dapat terlihat pada gambar berikut:



Gambar 76. Hubungan temperatur luar dengan curah hujan

Terlihat peningkatan suhu temperatur luar 8-12 jam sebelum terjadinya titik kejadian hujan. Dengan hasil ini dapat terlihat bahwa temperatur luar berkorelasi terhadap curah hujan dalam resolusi 8-12 jam lagging.



Gambar 77. Hubungan kec. angin, kelembaban dan curah hujan

Gambar di atas menunjukkan hubungan kecepatan angin maksimum (*rain gauge*) dan kelembaban terhadap curah hujan. Korelasinya bahkan dengan resolusi lebih kecil yaitu 5-8 jam. Terlihat *Rain Gauge* yang cukup tinggi dan kelembaban yang rendah sebelum terjadinya kejadian hujan.

Dengan dilengkapinya radar baru Teknik Unhas-LAPAN membuka potensi penelitian yang lebih besar. Bahkan penelitian kedepan diharapkan menemukan korelasi yang lebih dalam konteks hubungan meteorologi terhadap curah hujan dan terhadap parameter lainnya. Sehingga peningkatan hasil prediksi ke depannya akan sangat menjanjikan.

BAB V

KESIMPULAN DAN SARAN

A. Kesimpulan

1. Dari 6 Unsur meteorologi yang diperoleh dari BMKG, hanya 3 yang digunakan untuk pelatihan yaitu temperatur, kelembaban dan kecepatan angin. Keputusan ini diambil setelah uji korelasi terhadap curah hujan yang menunjukkan hanya ketiga unsur ini yang memiliki korelasi terbaik.
2. Digunakan 4 model prediksi kuantitatif *hybrid* kecerdasan buatan dan statistic dalam penelitian ini. Metode tersebut adalah *Wavelet*-JST, GA-JST, ARIMA dan ASTAR. ASTAR memberikan prediksi terbaik baik dari sisi tren maupun nilai RMSE yang cukup kecil. *Hybrid* Kecerdasan Buatan yang terbaik adalah GA-NN.
3. Digunakan 3 model prediksi kualitatif yaitu ANFIS, JST-*Fuzzy* dan SVM-*Fuzzy*. Hasilnya menunjukkan SVM-*Fuzzy* terbaik dari ketiga model yang ada dengan pencapaian prediksi sampai dengan 80%.
4. Persamaan model kuantitatif terbaik ASTAR dinyatakan dengan:

$$Y = kBF_0 + kBF_2 * (VP_1 - TK_1) + kBF_4 * (VP_2 - TK_2) + kBF_3 * (TK_3 - VP_2)$$
5. Parameter *Fuzzy* terbaik untuk pendekatan kualitatif adalah dengan nilai deviasi dari parameter kelembaban, temperatur dan kecepatan angin secara berturut-turut adalah 1.248, 10.547 dan 4.848.
6. Terjadi perbedaan keakuratan prediksi untuk tahun 2009 dan 2010. Hal ini disebabkan karena pada tahun 2010 terjadi La Nina yaitu hujan sepanjang

tahun, sedangkan data pelatihan yang digunakan 2004-2009 tidak menunjukkan indikasi La Nina.

B. Saran

1. Penelitian kedepan dapat dikembangkan dengan beberapa model *hybrid* kecerdasan buatan dan statistik yang belum pernah digunakan. Potensi *hybrid* 3 model dapat saja dilakukan untuk prediksi yang lebih baik dengan konsekuensi kompleksitas yang lebih tinggi.
2. Penggunaan sampling resolusi harian yang selama ini digunakan dalam penelitian-penelitian sebelumnya sebaiknya ditinjau ulang. Saran kepada pihak BMKG dan lembaga terkait untuk juga dapat menyediakan data sampling dengan resolusi per jam. Dengan adanya resolusi sampling yang lebih cepat akan memberikan gambaran korelasi unsur meteorologi yang lebih akurat dan berujung ke hasil prediksi yang lebih baik.

DAFTAR PUSTAKA

Abhishek, k., Kumar A, 2012, *A Rainfall Prediction Model using Artificial Neural Network*, IEEE Control and System Graduate Research Colloquium.

- Aldrian, E., Susanto, R.D. 2003. *Identification of Three Dominant Rainfall Regions Within Indonesia and Their Relationship to Sea Surface Temperature*. *Int. J. Climatol.* 23: 1435–1452.
- Aldrian, E., Djamil, YS. 2008. *Application of Multivariate Anfis for Daily Rainfall Prediction: Influences of Training Data Size*. *MAKARA, SAINS*. Volume 12, No. 1.
- Chen, Y., Luh P.B, Guan, C, Zhao, Y, Michel, L.D, Coolbeth, M. 2010. *Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks*. *IEEE TRANSACTIONS ON POWER SYSTEMS*. VOL. 25, NO. 1.
- Demuth, 2009. *Advanced in Neural Network, 6th International Symposium on Neural Networks*, ISSN 2009 Wuhan, China.
- French, M. N., Krajewski, W. F., and Cuykendall, R. R,1992.: *Rainfall forecasting in space and time using neural network*, *J. Hydrol.*,137, 1–31.
- Gan, X., 2011. *The research of rainfall prediction models based on Matlab neural network*. *Cloud Computing and Intelligence Systems (CCIS)*, 2011, IEEE.
- Giannini, A., Robertson, W.A, Qian, J-H, 2007. *A role for tropical tropospheric temperature adjustment to El Niño–Southern Oscillation in the seasonality of monsoonal Indonesia precipitation predictability*. *Journal of Geophysical Research*. VOL. 112, D16110.
- Han, Dawei, 2010. *Concise Hydrology*, Denmark : Ventus Publishing Aps.

- Hongxia, L., Chuanwei L, 2008. *Construction and Application of Fuzzy Neural Network Model in Precipitation Forecast of Sanjiang Plain, China*. International Conference on Wireless Communication, Networking and Mobile Computing (WiCOM).
- Indrabayu, 2011. *Neural Network and Fuzzy methods for rainfall prediction*, Proc. The 1stFortei Conference, Makassar, Indonesia, 2011, pp135 (In Indonesian)
- Iskandar, 2010, *Seasonal and interannual pattern of sea surface temperature in Banda Sea as revealed by self-organizing maps*, Continental Shelf Res. May 31, 2010
- Istriana, 2009. *Pemodelan Curah Hujan Dengan Pendekatan Adaptive Spline Threshold Autoregressive (ASTAR)*. From <http://digilib.its.ac.id/pemodelan-curah-hujan-dengan-pendekatanadaptive-spline-threshold-autoregressiveastar-6441.html>. 22 Desember 2009
- Kumar, A., Yang, F, Goduard L, Schubert, S. 2004. *Differing Trends in the Tropical Surface Temperatures and Precipitation over Land and Oceans*. *Journal of Climate*. Vol.17.
- Kear, Brian.J, 1979. *Element Of Geographical Hydrology*, London : Academic Division Of Unwin Hyman LTD.
- Lin, K., Lin, J, Chen, B, 2004. *Study on Short-range Precipitation Forecasting Method Based on Genetic Algorithm Neural Network*, 7th World Congress on Intelligent Control and Automation, Chongqing, China. IEEE Explore.
- Luo, F., Wu, C, Wu J, 2010. *A Novel Neural Network Ensemble Model Based on Sample Reconstruction and Projection Pursuit for Rainfall*

Forecasting. Sixth International Conference on Natural Computation (ICNC). IEEE Explore.

Lundquist, Jessica, 2010. "Hydrologic Process". From http://faculty.washington.edu/jdlund/classes/CEE345/Lundquist_ebook_2010_Hydrology.pdf

Mc Cuen, Richard H., 1998. *Hydrologic Analysis And Design Second Edition*, United States : Prentice Hall PTR.

Medvigy, D., and C. Beaulieu, 2012. *Changes in daily solar radiation and precipitation coefficients of variation since 1984*. J. Climate, 25, 1330-1339.

Manusthiparom C., Oki T., and Kame, S. 2003. *Quantitative Rainfall Prediction in Thailand*, First International Conference on Hydrology and Water Resources on Asia Pacific Region (APHW), Kyoto, Japan.

M.C. Ramirez, H.F. Velho, 2005. *Artificial neural network technique for rainfall forecasting applied to the São Paulo region*, Journal of Hydrology Volume 301, Issues 1-4.

Mendelsohn, Lou; Stein, Jon, 2007, *Fundamental Analysis Meets the Neural Network*. Magazine article from Futures (Cedar Falls, IA), Vol. 20, No. 10.

N. Q. Hung, M. S. Babel, S. Weesakul, and N. K. Tripathi, 2009. *An artificial neural network model for rainfall forecasting in Bangkok, Thailand*. Hydrol. Earth Syst. Sci., 13, 1413–1425.

Nong, J., Jin, L., 2008. *Application of Support Vector Machine to Predict Precipitation*. Proceedings of the 7th World Congress on Intelligent Control and Automation. Chongqing, China. IEEE Explore.

- Nong, J. 2010. *The Short-range Precipitation Forecasting Method of Neural Network Based on Principal Component Analysis*. Third International Joint Conference on Computational Science and Optimization. IEEE Explore.
- Ragunath,H.M,2007.*Hydrology : Principle, Analysis, Design*, New Delhi : New Age International Publisher.
- Sheng, LL., Cheng, WQ, Xia, H, Zhang X, 2010. *Prediction Of Annual Precipitation Based On Fuzzy And Grey Markov Process*. Proceedings of the Ninth International Conference on Machine Learning and Cybernetics, Qingdao.
- Solaimani, K, 2009. *Rainfall-runoff Prediction Based on Artificial Neural Network (A Case Study Parahi Watershed)*. *American-Eurasian Journal. Agric. & Environ. Sci* 5 (6): 856-865. IDOSI Publications.
- Sonjaya, I., Kurniawan T, 2009. *Uji Aplikasi Hybmg Versi 2.0 untuk Prakiraan Curah Hujan Pola Monsunal Ekuatorial dan Lokal*. *Buletin Meteorologi Klimatologi Dan Geofisika*. Vol.5 No.3.
- Speer, K., N. Lovenduski, M. H. England, D. W. J. Thompson, C. Beswick, 2012: *Developing a vision for climate variability research in the Southern Ocean-Ice-Atmosphere system*, CLIVAR Exchanges, 17, No. 1, 43-45
- Susilowati, 2010. *Pokok-pokok Klimatologi*, Ganesha Bandung.

- Subarna, D. 2009. *Aplikasi Jaringan Neural Untuk Pemodelan dan Prediksi Curah Hujan*. Berita Dirgantara. Vol.10 No.1.
- Shaw, Elizabeth. M., Beven, Keith, J, Chapbell, Nick, A, Lamb, Rob. 2011. *Hydrology In Practice Fourth Edition*. Oxon : Spon Press.
- T. Terasvirta, A.B. Kock, 2010, *Forecasting with Nonlinear Time Series Models*, CREATES Research Paper No. 2010-1.
- Warsito, B., Sumiyati, S, 2007. *Prediksi Curah Hujan Kota Semarang Dengan Feedforward Neural Network Menggunakan Algoritma Quasi Newton Bfgs Dan Levenberg-Marquardt*. *Jurnal PRESIPITASI*. Vol. 3 No.2.
- Wu H., Lin X, 2009. *Application of Fuzzy Neural Network to the Flood Season Precipitation Forecast*. International Joint Conference on Computational Sciences and Optimization. IEEE Explore.
- Zao J., Astron J, 2004, *The Effect of Solar Activity on the Annual Precipitation in the Beijing Area*. Chinese Journal of Astronomy and Astrophysics Volume 4 Number 2.