

MODEL PRAKIRAAN CURAH HUJAN
DI KABUPATEN BANYUWANGI
MENGUNAKAN METODE JARINGAN SYARAF TIRUAN
DENGAN *BACK-PROPAGATION*

Skripsi
Disusun untuk melengkapi syarat-syarat
memperoleh gelar Sarjana Sains



Sifa Afnada Nailufar
3125102326

PROGRAM STUDI MATEMATIKA
JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI JAKARTA
2015

PERSEMBAHANKU...

Skripsi ini kupersembahkan untuk....

kedua orangtuaku Muttaqin dan Jauharotuz Zahro,
kakang-kakakku Ivana Rosfiana, Silvia Ridayanti, Ali Muzaqqi S.,
Musthofa Kamal, dan Yuni Fatmalasari, serta keluarga besarku.

"Terima kasih atas bantuan, dukungan, do'a, serta kasih sayang kalian... "

ABSTRACT

SIFA AFNADA NAILUFAR, 3125102326. Rainfall Prediction Model at Banyuwangi Regency Using Artificial Neural Network With Back-propagation Method. 2014.

This thesis discusses how to build a rainfall prediction model for BMKG's Banyuwangi Regency data using Artificial Neural Network with back-propagation method. Rainfall is an important factor for plant growth (in agriculture). The activation function is binary sigmoid. There is nine experiments, which is next 1 month, 2 months, 3 months, 4 months, 5 months, 6 months, 9 months, 12 months, and 18 months. Based on the $E_{testing}$ result, the best model is rainfall prediction for next 9 months using network configuration that consist of three nodes in input layer (air temperature, humidity, and air pressure), seven nodes in hidden layer, and one node in output layer (rainfall). The accuracy of model in learning process and testing process is 0.0278 and 0.0088 respectively.

Keyword : rainfall, air temperature, humidity, air pressure, normalization, prediction, *artificial neural network*, *back-propagation*, accuracy.

ABSTRAK

SIFA AFNADA NAILUFAR, 3125102326. Model Prakiraan Curah Hujan di Kabupaten Banyuwangi Menggunakan Metode Jaringan Syaraf Tiruan Dengan *Back-Propagation*. Skripsi. Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta. 2014.

Skripsi ini membahas bagaimana membangun model prakiraan curah hujan untuk data BMKG Kabupaten Banyuwangi menggunakan metode Jaringan Syaraf Tiruan dengan *back-propagation*. Curah hujan merupakan faktor yang sangat mempengaruhi pertumbuhan tanaman (dalam pertanian). Fungsi aktivasi yang digunakan adalah sigmoid biner. Dilakukan sembilan percobaan, yaitu prakiraan curah hujan untuk 1 bulan, 2 bulan, 3 bulan, 4 bulan, 5 bulan, 6 bulan, 9 bulan, 12 bulan dan 18 bulan ke depan. Berdasarkan nilai $E_{pengujian}$ nya, model yang terbaik adalah prakiraan curah hujan 9 bulan ke depan menggunakan konfigurasi jaringan yang terdiri dari tiga simpul pada lapisan masukan yaitu suhu udara, kelembapan udara, dan tekanan udara; 7 simpul pada lapisan tersembunyi; dan satu simpul pada lapisan keluaran yaitu curah hujan. Nilai akurasi model tersebut pada proses pelatihan dan pengujian secara berturut-turut sebesar 0.0278 dan 0.0088.

Kata kunci : curah hujan, suhu udara, kelembapan udara, tekanan udara, normalisasi, prakiraan, jaringan syaraf tiruan, *back-propagation*, akurasi.

KATA PENGANTAR

Puji syukur kepada Allah SWT atas pemberian pengetahuan dan kemampuan sehingga penulis dapat menyelesaikan skripsi yang berjudul "Model Praktek Curah Hujan di Kabupaten Banyuwangi Menggunakan Metode Jaringan Syaraf Tiruan Dengan *Back-Propagation*" yang merupakan salah satu syarat dalam memperoleh gelar Sarjana Jurusan Matematika Universitas Negeri Jakarta.

Skripsi ini berhasil diselesaikan tak lepas dari bantuan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan terima kasih kepada:

1. Bapak Drs. Mulyono, M.Kom. selaku Dosen Pembimbing I dan Bapak Med Irzal, M.Kom. selaku Dosen Pembimbing II yang telah meluangkan waktu, saran, nasihat, serta pengarahan dalam pengerjaan skripsi ini sehingga menjadi lebih baik. Terima kasih banyak dan maaf atas segala kekurangan penulis, semoga kesehatan dan kebahagiaan selalu tercurah kepada Bapak dan keluarga.
2. Bapak Drs. Makmuri, M.Si. selaku Ketua Jurusan Matematika FMIPA UNJ dan Ibu Ratna Widyanti, S.Si, M.Kom. selaku Ketua Prodi Matematika FMIPA UNJ. Terima kasih atas segala bantuan dan kerja sama Bapak dan Ibu selama pengerjaan skripsi ini.
3. Bapak Drs. Tri Murdiyanto, M.Si. selaku Pembimbing Akademik atas segala bimbingan Bapak selama perkuliahan saya, seluruh Bapak/Ibu dosen atas pengajaran yang telah diberikan, serta karyawan/karyawati FMIPA UNJ lainnya atas informasi dan bantuan yang diberikan dalam menyelesaikan skripsi ini.

4. Kedua orang tuaku dan kakak-kakakku tercinta yang senantiasa memberikan doa, semangat, kesabaran, nasihat, serta bantuan secara moral maupun material.
5. Sahabat-sahabatku tersayang Annisa, Novilia Eka Chandra R. N., RR Muditaa Candra Kirana, Riska Novita Sari, Diesty Chelvia, dan teman-teman Matematika 2010 lainnya. Terima kasih atas segala dukungan, kerja sama, perhatian, dan kebersamaan yang diberikan, semoga persahabatan kita selamanya.
6. Yayuk Sugiarti dan seluruh pihak yang telah membantu. Terima kasih atas segala bantuan dan dukungan selama pengerjaan skripsi ini.

Penulis menyadari skripsi ini masih jauh dari sempurna. Masukan dan kritik akan sangat berarti. Semoga skripsi ini dapat bermanfaat bagi pembaca.

Jakarta, Desember 2014

Sifa Afnada Nailufar

DAFTAR ISI

ABSTRACT	i
ABSTRAK	ii
KATA PENGANTAR	iii
DAFTAR ISI	vi
DAFTAR TABEL	vii
DAFTAR GAMBAR	viii
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Perumusan Masalah	2
1.3 Pembatasan Masalah	3
1.4 Tujuan Penulisan	3
1.5 Manfaat Penulisan	3
1.6 Metode Penelitian	4
II LANDASAN TEORI	5
2.1 Curah Hujan	5
2.2 Peramalan	7
2.2.1 Prakiraan Cuaca	7
2.3 Jaringan Syaraf Tiruan	9
2.3.1 Arsitektur Jaringan (Konfigurasi Jaringan)	10

2.3.2	Algoritma Belajar atau Pelatihan	15
2.4	<i>Back-propagation</i>	16
2.4.1	Fungsi Aktivasi	16
2.4.2	Pelatihan <i>Back-propagation</i>	17
2.5	Transformasi Data	29
2.6	Akurasi Model	30
III PEMBAHASAN		32
3.1	Data Yang Diamati	32
3.2	Prosedur Pengolahan Data	32
3.3	Hasil Pengolahan Data	36
3.3.1	Model prakiraan curah hujan 1 bulan ke depan	37
3.3.2	Model prakiraan curah hujan 2 bulan ke depan	39
3.3.3	Model prakiraan curah hujan 3 bulan ke depan	40
3.3.4	Model prakiraan curah hujan 4 bulan ke depan	42
3.3.5	Model prakiraan curah hujan 5 bulan ke depan	42
3.3.6	Model prakiraan curah hujan 6 bulan ke depan	44
3.3.7	Model prakiraan curah hujan 9 bulan ke depan	45
3.3.8	Model prakiraan curah hujan 12 bulan ke depan	47
3.3.9	Model prakiraan curah hujan 18 bulan ke depan	47
IV PENUTUP		51
4.1	Kesimpulan	51
4.2	Saran	52
LAMPIRAN		55

DAFTAR TABEL

2.1	Data Pelatihan	22
3.1	Proses Pengujian Model Prakiraan Curah Hujan 1 Bulan Ke Depan	39
3.2	Proses Pengujian Model Prakiraan Curah Hujan 2 Bulan Ke Depan	40
3.3	Proses Pengujian Model Prakiraan Curah Hujan 3 Bulan Ke Depan	41
3.4	Proses Pengujian Model Prakiraan Curah Hujan 4 Bulan Ke Depan	43
3.5	Proses Pengujian Model Prakiraan Curah Hujan 5 Bulan Ke Depan	44
3.6	Proses Pengujian Model Prakiraan Curah Hujan 6 Bulan Ke Depan	45
3.7	Proses Pengujian Model Prakiraan Curah Hujan 9 Bulan Ke Depan	46
3.8	Proses Pengujian Model Prakiraan Curah Hujan 12 Bulan Ke Depan	48
3.9	Proses Pengujian Model Prakiraan Curah Hujan 18 Bulan Ke Depan	49
3.10	Perbandingan prakiraan t-bulan ke depan	49
3.11	Perbandingan banyaknya masukan	50
4.1	Suhu Udara, Kelembapan Udara, Tekanan Udara, dan Curah Hujan Bulanan Tahun 2004 - 2013	55

DAFTAR GAMBAR

2.1	Alat Penakar Hujan	5
2.2	Jaringan Layar Tunggal	11
2.3	Jaringan Layar Jamak	12
2.4	<i>Jordan Network</i>	14
2.5	Fungsi Sigmoid Biner	17
2.6	Model Jaringan Contoh 2.4.1	21
3.1	Diagram Prosedur Pengolahan Data	33
3.2	Model Jaringan	35
3.3	Model Jaringan 1 Input	50

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Indonesia dikenal sebagai negara agraris yang memiliki kekayaan sumber daya alam, terutama dari hasil pertanian. Sektor pertanian menjadi sektor penting sebagai penyedia input bagi sektor lain, sehingga sektor pertanian dikatakan berpengaruh dalam struktur perekonomian Indonesia. Sebagian besar penduduk Indonesia menempati wilayah pedesaan dan mereka hidupnya sangat bergantung pada sektor pertanian (BPS, 2012). Sektor pertanian di Indonesia sungguh sangat strategis untuk meningkatkan taraf hidup penduduk di pedesaan, penyediaan pangan bagi seluruh penduduk Indonesia.

Sektor pertanian ini sangatlah dipengaruhi oleh iklim, yang merupakan salah satu faktor yang mempengaruhi pertumbuhan dan produktivitas tanaman. Faktor-faktor cuaca yang sangat mempengaruhi pertumbuhan tanaman adalah curah hujan (terutama untuk pertanian lahan kering) dan suhu. Prakiraan cuaca merupakan suatu usaha manusia untuk melihat perkembangan kondisi iklim yang lalu, sekarang, dan yang akan datang khususnya dalam kaitan mengantisipasi. Variabel-variabel utamanya adalah suhu udara, sinar matahari, kelembapan udara, awan, hujan dan angin serta tekanan atmosfer.

Metode yang digunakan untuk prakiraan secara statistik salah satunya yaitu *Auto Regressive Integrated Moving Average* (ARIMA), metode tersebut

telah digunakan untuk prakiraan curah hujan. Namun ada metode prakiraan yang dapat diaplikasikan dengan lebih baik dari metode konvensional tersebut yaitu Jaringan Syaraf Tiruan (*Artificial Neural Network*) (W, Anugrah, 2007). Sistem kepakaran Jaringan Syaraf Tiruan mampu menyederhanakan sistem kompleks dan mempunyai kelebihan dalam pembelajaran (*training*) dan mampu beradaptasi. Salah satu metode pembelajaran pada Jaringan Syaraf Tiruan adalah algoritma *back-propagation*. Algoritma *back-propagation* bekerja berdasarkan pada pola data yang ada pada masa lalu. Dari sini dapat diketahui tren yang paling mirip dengan sekarang. Jika datanya cukup, maka prakiraannya semakin bagus dan tingkat akurasi lebih baik. *Back-propagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan dan kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa (tapi tidak sama) dengan pola yang dipakai selama pelatihan.

Pada penelitian ini, penulis ingin menggunakan model dari Jaringan Syaraf Tiruan dengan *back-propagation* untuk prakiraan curah hujan berdasarkan suhu udara, kelembapan udara, dan tekanan udara di Kabupaten Banyuwangi, Jawa Timur.

1.2 Perumusan Masalah

Berdasarkan uraian pada latar belakang dapat dirumuskan masalah yang akan dikaji adalah sebagai berikut:

1. Bagaimana membangun model prakiraan curah hujan berdasarkan suhu udara, kelembapan udara, dan tekanan udara di Kabupaten Banyuwangi?

2. Berapa besar tingkat akurasi model untuk prakiraan curah hujan yang digunakan tersebut?

1.3 Pembatasan Masalah

Masalah yang akan diteliti dalam membangun model prakiraan curah hujan ini dibatasi menggunakan metode Jaringan Syaraf Tiruan dengan *back-propagation* dan data Badan Meteorologi Klimatologi dan Geofisika (BMKG) Kabupaten Banyuwangi.

1.4 Tujuan Penulisan

Tujuan yang ingin dicapai dalam penelitian ini adalah membangun model prakiraan curah hujan di Kabupaten Banyuwangi berdasarkan suhu udara, kelembapan udara, dan tekanan udara, dengan melihat tingkat akurasi model.

1.5 Manfaat Penulisan

Manfaat yang diharapkan dari penelitian ini adalah

1. Bagi Penulis

Mendapatkan pengetahuan yang baru mengenai prakiraan curah hujan yang belum di dapat dari perkuliahan.

2. Bagi Pembaca atau Pengguna

Mendapatkan wawasan mengenai prakiraan cuaca menggunakan metode Jaringan Syaraf Tiruan dengan *back-propagation*.

1.6 Metode Penelitian

Skripsi ini merupakan kajian teori tentang prakiraan curah hujan berdasarkan suhu udara, kelembapan udara, dan tekanan udara yang didasarkan pada buku-buku dan jurnal-jurnal tentang prakiraan menggunakan metode Jaringan Syaraf Tiruan dengan *back-propagation*.

BAB II

LANDASAN TEORI

2.1 Curah Hujan

Hujan merupakan salah satu bentuk presipitasi (pengendapan) uap air yang berasal dari awan yang terdapat di atmosfer. Bentuk presipitasi lainnya adalah salju dan es. Untuk dapat terjadinya hujan diperlukan titik-titik kondensasi, amoniak, debu dan asam belerang. Titik-titik kondensasi ini mempunyai sifat dapat mengambil uap air dari udara. Satuan curah hujan selalu dinyatakan dalam satuan milimeter atau inci, di Indonesia satuan curah hujan yang digunakan adalah satuan milimeter (mm).



Gambar 2.1: Alat Penakar Hujan

Curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir. Pengukuran curah hujan dilakukan melalui alat yang disebut penakar curah hujan (Gambar 2.1). Curah hujan 1 (satu) mm artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu milimeter atau tertampung air sebanyak satu liter (Nasution, 2010).

Berdasarkan faktor yang menyebabkan terjadinya, hujan dibedakan menjadi empat tipe, yaitu:

- Hujan Orografi

Curah hujannya berbeda menurut ketinggian, biasanya curah hujan makin besar pada tempat-tempat yang lebih tinggi sampai suatu ketinggian tertentu.

- Hujan Konvektif

Hujan ini merupakan hujan yang paling umum yang terjadi di daerah tropis. Panas yang menyebabkan udara naik ke atas kemudian mengembang dan secara dinamika menjadi dingin dan berkondensasi dan akan jatuh sebagai hujan.

- Hujan Frontal

Terjadinya hujan ini dipengaruhi oleh front. Hujan front ini tidak terjadi di Indonesia karena di Indonesia tidak terjadi front.

- Hujan Siklon Tropis

Siklon tropis hanya dapat timbul di daerah tropis antara lintang 0° – 10° lintang utara dan selatan, tidak berkaitan dengan front karena siklon ini berkaitan dengan sistem tekanan rendah.

2.2 Peramalan

Peramalan pada dasarnya merupakan proses menyusun informasi tentang kejadian masa lampau yang berurutan untuk menduga kejadian di masa depan. Pada umumnya, peramalan digunakan untuk memprediksi sesuatu yang kemungkinan besar akan terjadi misalnya kondisi permintaan, banyaknya curah hujan, kondisi ekonomi, dan lain-lain. (Herjanto, 2008)

Berdasarkan sifatnya, peramalan dibedakan menjadi 2, yaitu:

- Peramalan Kualitatif

Peramalan yang didasarkan pada pengamatan kejadian-kejadian di masa sebelumnya digabung dengan pemikiran dari penyusunnya.

- Peramalan Kuantitatif

Peramalan yang didasarkan atas data kuantitatif masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Hasil peramalan yang dibuat tergantung pada metode yang digunakan, menggunakan metode yang berbeda akan diperoleh hasil peramalan yang berbeda.

2.2.1 Prakiraan Cuaca

Cuaca adalah total dari keseluruhan variabel atmosfer di suatu tempat dalam jangka waktu yang singkat, sedangkan iklim berbicara mengenai bagaimana perilaku atmosfer dalam jangka waktu yang lama. Perbedaan antara cuaca dan iklim adalah pada ukuran waktunya. Iklim merupakan kumulatif dari keadaan cuaca yang sering dijelaskan dalam rata-rata terutama pada suhu dan presipitasi serta angin.

Prakiraan cuaca adalah aplikasi ilmu pengetahuan dan teknologi un-

tuk memprediksi keadaan atmosfer di lokasi tertentu. Hal ini dibuat dengan mengumpulkan data kuantitatif tentang keadaan atmosfer saat ini di suatu tempat dan menggunakan pemahaman ilmiah tentang proses atmosfer untuk merancang bagaimana keadaan akan berkembang di daerah tersebut.

Variabel-variabel utamanya adalah suhu udara, sinar matahari, kelembapan udara, awan, hujan dan angin serta tekanan atmosfer. Tekanan atmosfer menentukan arah dan kecepatan angin dan menggerakkan massa udara yang berbeda suhu dan kelembapannya dari satu lokasi ke lokasi lainnya. Sementara itu pergerakan udara bergerak secara horizontal dan vertikal. Jika pergerakan udara tersebut adalah vertikal maka akan cenderung terjadi awan dan hujan.

Prakiraan cuaca merupakan ramalan penting karena digunakan untuk melindungi kehidupan dan lingkungan. Peramalan berdasarkan suhu dan curah hujan penting bagi pertanian. Dalam keseharian, orang menggunakan prakiraan cuaca untuk menentukan apa yang akan dikenakan pada hari tertentu. Selain itu, karena kegiatan di luar ruangan sangat dibatasi oleh hujan lebat, salju dan angin dingin, prakiraan cuaca dapat digunakan juga untuk merencanakan kegiatan yang memanfaatkan cuaca/keadaan saat ini dan untuk merencanakan masa mendatang, serta menyelamatkan mereka dari cuaca buruk.

Prakiraan cuaca numerik menggunakan model matematika dari atmosfer dan lautan untuk memprediksi cuaca berdasarkan kondisi cuaca saat ini. Meskipun simulasi komputer dimulai pada tahun 1920-an, tetapi prakiraan cuaca numerik yang realistis baru dihasilkan pada tahun 1950. Sejumlah model prakiraan global dan regional dijalankan di berbagai negara di seluruh dunia dengan menggunakan pengamatan cuaca saat ini dari satelit cuaca sebagai masukan untuk model.

2.3 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (*Artificial Neural Network*) dapat diartikan sebagai model komputasi yang bekerja seperti sistem syaraf biologis dengan sifat tertentu, seperti kemampuan beradaptasi atau belajar, generalisasi, *cluster* atau mengatur data, dan merupakan operasi yang didasarkan pada pemrosesan paralel.

Jaringan syaraf tiruan dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi sebagai berikut:

- Pemrosesan informasi terjadi pada banyak neuron.
- Sinyal dikirimkan diantara neuron-neuron melalui penghubung-penghubung.
- Penghubung antar neuron memiliki bobot yang akan memperkuat atau memperlemah sinyal.
- Untuk menentukan keluaran (*output*), setiap neuron menggunakan fungsi aktivasi yang dikenakan pada penjumlahan masukan (*input*) yang diterima. Besarnya keluaran (*output*) ini selanjutnya dibandingkan dengan suatu batas ambang.

Neuron adalah unit pemroses informasi yang menjadi dasar dalam pengoperasian jaringan syaraf tiruan. Istilah simpul (*node*) sering digunakan untuk menggantikan neuron.

Terdapat 3 (tiga) jenis lapis simpul, yang terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*). Tiap lapisan terdiri dari satu atau beberapa simpul. Dimana dalam masing-masing simpul dilakukan pemrosesan atau pengolahan dari masukan (*input*) yang hasilnya berupa keluaran (*output*).

Jaringan syaraf tiruan ditentukan oleh 3 hal sebagai berikut:

1. Pola hubungan antar neuron disebut arsitektur jaringan.
2. Metode untuk menentukan bobot penghubung disebut algoritma training (learning/pelatihan).
3. Fungsi aktivasi.

Setiap simpul pada jaringan menerima atau mengirim sinyal dari atau ke simpul-simpul lainnya. Pengiriman sinyal disampaikan melalui penghubung. Kekuatan hubungan yang terjadi antara setiap simpul yang saling terhubung dikenal dengan nama bobot. Model-model jaringan syaraf tiruan ditentukan oleh arsitektur jaringan serta algoritma pelatihan. Arsitektur biasanya menjelaskan arah perjalanan sinyal atau data di dalam jaringan. Sementara itu algoritma belajar menjelaskan bagaimana bobot koneksi harus diubah agar pasangan masukan-keluaran yang diinginkan dapat tercapai.

Perubahan harga bobot koneksi dapat dilakukan dengan berbagai cara, tergantung pada jenis algoritma pelatihan yang digunakan. Dengan mengatur besarnya nilai bobot ini diharapkan bahwa kinerja jaringan dalam mempelajari berbagai macam pola yang dinyatakan oleh setiap pasangan masukan-keluaran akan meningkat.


2.3.1 Arsitektur Jaringan (Konfigurasi Jaringan)

Berdasarkan arsitekturnya, model jaringan syaraf tiruan digolongkan menjadi:

1. **Jaringan Layar Tunggal (*Single Layer Network*)**

Pada jaringan ini, sekumpulan simpul masukan dihubungkan langsung dengan sekumpulan keluarannya. Sinyal mengalir searah dari lapisan masukan

sampai lapisan keluaran. Setiap simpul dihubungkan dengan simpul lainnya yang berada di atasnya dan dibawahnya, tetapi tidak dengan simpul yang berada pada lapisan yang sama. Artinya setiap simpul masukan mempengaruhi simpul-simpul keluaran, tetapi simpul-simpul keluarannya saling bebas. Model yang masuk kategori ini antara lain: ADALINE, *Perceptron*, dan lain-lain. Pada gambar 2.2 diperlihatkan arsitektur jaringan layar tunggal.



Gambar 2.2: Jaringan Layar Tunggal

z_o dapat dihitung dengan rumus:

$$z_o = f(s_o) \quad (2.1)$$

Dimana s_o merupakan jumlah perkalian nilai masukan (x_j) dengan bobot (w_{jo}) dan ditambah bias pada setiap simpul keluaran (θ_o).

$$s_o = \sum_j w_{jo}x_j + \theta_o \quad (2.2)$$

Keterangan :

x_j : simpul masukan ke- j

z_o : simpul keluaran ke- o

n : banyaknya simpul pada lapisan masukan

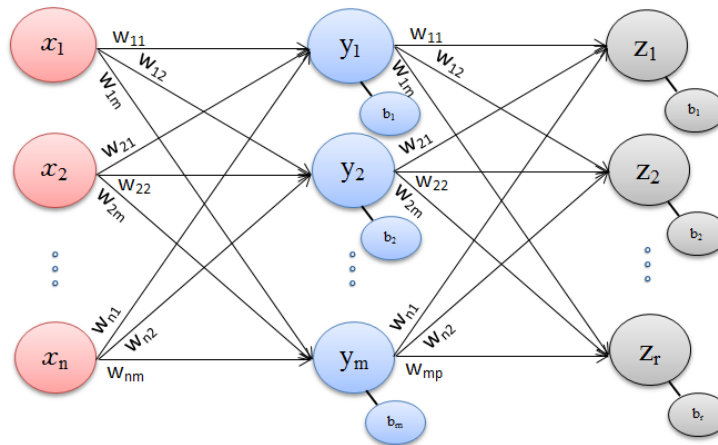
r : banyaknya simpul pada lapisan keluaran

w_{jo} : bobot yang menghubungkan lapisan masukan dengan lapisan keluaran

b_o : bias pada lapisan keluaran (θ_o)

2. Jaringan Layar Jamak (*Multiple Layer Network*)

Jaringan ini merupakan perluasan dari jaringan layar tunggal. Dalam jaringan ini, selain unit masukan dan keluaran, ada unit-unit lain (sering disebut layar tersembunyi). Dimungkinkan pula ada beberapa layar tersembunyi. Model yang termasuk kategori ini antara lain: MADALINE, *Back-propagation*. Pada gambar 2.3 diperlihatkan jaringan dengan sebuah layar tersembunyi.



Gambar 2.3: Jaringan Layar Jamak

Pada jaringan layar jamak, untuk menghitung nilai z_o pada lapisan keluaran, terlebih dahulu hitung nilai y_k pada lapisan tersembunyi. y_k dapat

dihitung dengan rumus:

$$y_k = f(s_k) \quad (2.3)$$

Dimana s_k merupakan jumlah perkalian nilai masukan (x_j) dengan bobot (w_{jk}) dan ditambah bias pada setiap simpul tersembunyi (θ_k).

$$s_k = \sum_j w_{jk}x_j + \theta_k \quad (2.4)$$

Proses tersebut diulang jika ada lebih dari satu lapisan tersembunyi.

Kemudian hitung nilai z_o dengan rumus:

$$z_o = f(s_o) \quad (2.5)$$

Dimana s_o merupakan jumlah perkalian nilai y_k dengan bobot (w_{ko}) dan ditambah bias (θ_o).

$$s_o = \sum_k w_{ko}y_k + \theta_o \quad (2.6)$$

Keterangan :

x_j : simpul masukan ke- j

y_k : simpul tersembunyi ke- k

z_o : simpul keluaran ke- o

n : banyaknya simpul pada lapisan masukan

m : banyaknya simpul pada lapisan tersembunyi

r : banyaknya simpul pada lapisan keluaran

w_{jk} : bobot yang menghubungkan lapisan masukan dengan lapisan tersembunyi

w_{ko} : bobot yang menghubungkan lapisan tersembunyi dengan lapisan kelu-


aran

b_k : bias pada lapisan tersembunyi (θ_k)

b_o : bias pada lapisan keluaran (θ_o)

3. Jaringan *Recurrent*

Model jaringan *recurrent* (*recurrent network*) mirip dengan jaringan layar tunggal ataupun jamak. Hanya saja, ada simpul keluaran yang memberikan sinyal pada unit masukan (sering disebut *feedback loop*). Dengan kata lain sinyal mengalir dua arah, yaitu maju dan mundur. Contoh: *Jordan network* (gambar 2.4, *Elmal network*).



Gambar 2.4: *Jordan Network*

Keterangan :

x_j : simpul masukan ke- j

y_k : simpul tersembunyi ke- k

z_o : simpul keluaran ke- o

n : banyaknya simpul pada lapisan masukan

m : banyaknya simpul pada lapisan tersembunyi

r : banyaknya simpul pada lapisan keluaran

w_{jk} : bobot yang menghubungkan lapisan masukan dengan lapisan tersembunyi

w_{ko} : bobot yang menghubungkan lapisan tersembunyi dengan lapisan keluaran

b_k : bias pada lapisan tersembunyi

b_o : bias pada lapisan keluaran

u : masukan baru yang didapat dari nilai keluaran

2.3.2 Algoritma Belajar atau Pelatihan

Ide dasar jaringan syaraf tiruan adalah konsep belajar atau pelatihan. Untuk dapat menyelesaikan suatu permasalahan, jaringan syaraf tiruan memerlukan algoritma belajar atau pelatihan yaitu bagaimana sebuah konfigurasi jaringan dapat dilatih untuk mempelajari data historis yang ada. Dengan pelatihan ini, pengetahuan yang terdapat pada data dapat diserap dan direpresentasikan oleh harga-harga bobot koneksinya.

Algoritma belajar atau pelatihan digolongkan menjadi sebagai berikut:

1. Supervisi (*Supervised Learning*)

Dalam pelatihan dengan supervisi, terdapat sejumlah pasangan data (masukan dan target keluaran) yang dipakai untuk melatih jaringan. Pada setiap pelatihan, suatu masukan diberikan ke jaringan. Jaringan akan memproses dan mengeluarkan keluaran. Selisih antara keluaran jaringan dengan target (keluaran yang diinginkan) merupakan kesalahan yang terjadi. Jaringan akan memodifikasi bobot sesuai dengan kesalahan tersebut. Model yang menggunakan pelatihan dengan supervisi antara lain: *Perceptron*,

ADALINE, MADALINE, *Back-propagation*.

2. Tanpa Supervisi (*Unsupervised Learning*)

Dalam pelatihannya, perubahan bobot jaringan dilakukan berdasarkan parameter tertentu dan jaringan dimodifikasi menurut ukuran parameter tersebut. Model yang menggunakan pelatihan ini adalah model jaringan kompetitif.

2.4 *Back-propagation*

Back-propagation merupakan model jaringan syaraf tiruan dengan layar jamak. Seperti halnya model jaringan syaraf tiruan lainnya, *back-propagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan dan kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa (tapi tidak sama) dengan pola yang dipakai selama pelatihan.

2.4.1 Fungsi Aktivasi


Dalam *back-propagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat sebagai berikut:

1. Kontinu
2. Terdiferensial dengan mudah.
3. Merupakan fungsi yang tidak turun.

Salah satu fungsi yang memenuhi ketiga syarat tersebut sehingga sering digunakan adalah fungsi sigmoid biner (berbentuk S) yang memiliki range $[0,1]$

seperti pada gambar 2.5. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai output yang terletak pada interval 0 sampai 1. Fungsi sigmoid biner didefinisikan sebagai berikut:

$$f(s) = \frac{1}{1 + e^{-s}} \quad (2.7)$$



Gambar 2.5: Fungsi Sigmoid Biner

$$f'(s) = \frac{1}{(1 + e^{-s})^2} * e^{-s} = \frac{e^{-s}}{(1 + e^{-s})^2} \quad (2.8)$$

Untuk pola yang targetnya lebih dari 1, pola masukan dan keluaran harus terlebih dahulu ditransformasi sehingga semua polanya memiliki range yang sama seperti fungsi sigmoid yang dipakai.

2.4.2 Pelatihan *Back-propagation*

Pada jaringan *back-propagation*, pelatihan dilakukan dalam rangka perhitungan bobot sehingga pada akhir pelatihan akan diperoleh bobot-bobot yang baik. Selama proses pelatihan, bobot-bobot diatur secara iteratif untuk meminimumkan *error* (kesalahan) yang terjadi.

Pelatihan *back-propagation* meliputi 3 fase sebagai berikut:

1. **Fase 1**, yaitu **perambatan maju**. Pola masukan dihitung maju mulai

dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang ditentukan.

2. **Fase 2**, yaitu **propagasi mundur**. Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan yang terjadi itu dipropagasi mundur. Dimulai dari garis yang berhubungan langsung dengan unit-unit di layar keluaran.
3. **Fase 3**, yaitu **perubahan bobot**. Modifikasi bobot untuk menurunkan kesalahan yang terjadi.

Ketiga fase tersebut diulang terus-menerus hingga kondisi penghentian dipenuhi.

Algoritma pelatihan untuk jaringan *back-propagation* dengan masukan $x_j (j = 1, 2, \dots, n)$ satu lapisan tersembunyi dan satu lapisan keluaran adalah sebagai berikut:

- **Langkah 1**

Inisialisasi semua bobot dengan bilangan acak kecil dengan range $[-1,1]$.

- **Langkah 2**

Untuk setiap pasang data pelatihan, lakukan langkah 4-9. Tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi di sampingnya.

- **Langkah 3** (langkah 3-4 merupakan **fase 1**)

Hitung semua keluaran di lapisan tersembunyi $y_k (k = 1, 2, \dots, m)$ menggunakan rumus 2.3 dan 2.4 dengan fungsi aktivasi sigmoid biner, sehingga

$$f(s_k) = \frac{1}{1 + e^{-s_k}}$$

- **Langkah 4**

Hitung semua keluaran jaringan di lapisan keluaran z_o ($o = 1, 2, \dots, r$) menggunakan rumus 2.5 dan 2.6 dengan fungsi aktivasi sigmoid biner, sehingga

$$f(s_o) = \frac{1}{1 + e^{-s_o}}$$

- **Langkah 5** (langkah 5-6 merupakan **fase 2**)

Hitung faktor δ unit keluaran berdasarkan kesalahan di setiap unit keluaran z_o ($o = 1, 2, \dots, r$).

$$\delta_o = (d_o - z_o)F'(s_o) \quad (2.9)$$

δ_o merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layar dibawahnya dan d_o merupakan target keluaran.

Hitung perubahan bobot w_{jk} dengan laju pemahaman (learning rate) γ .

$$\Delta w_{ko} = \gamma \delta_o y_k \quad (2.10)$$

- **Langkah 6**

Hitung faktor δ unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi y_k ($k = 1, 2, \dots, m$).

$$\delta_k = F'(s_k) \sum_{o=1}^r \delta_o w_{ko} \quad (2.11)$$

Hitung suku perubahan bobot w_{jk} .

$$\Delta w_{jk} = \gamma \delta_k x_j \quad (2.12)$$

- **Langkah 7 (fase 3)**

Hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit keluaran, yaitu:

$$w_{ko}(\text{baru}) = w_{ko}(\text{lama}) + \Delta w_{ko} \quad (2.13)$$

Perubahan bobot garis yang menuju ke unit tersembunyi, yaitu:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.14)$$

Keterangan :

x : lapisan masukan

y : lapisan tersembunyi

z : lapisan keluaran

n : jumlah neuron pada lapisan masukan

m : jumlah neuron pada lapisan tersembunyi

r : jumlah neuron pada lapisan keluaran

w_{jk} : bobot yang menghubungkan lapisan masukan dengan lapisan tersembunyi

w_{ko} : bobot yang menghubungkan lapisan tersembunyi dengan lapisan keluaran

b_k : bias pada lapisan tersembunyi

b_o : bias pada lapisan keluaran


Parameter γ merupakan laju pemahaman yang menentukan kecepatan iterasi. Nilai γ terletak antara 0 dan 1 ($0 \leq \gamma \leq 1$). Semakin besar harga γ , semakin sedikit iterasi yang dipakai. Akan tetapi jika harga γ terlalu besar, maka akan merusak pola yang sudah benar sehingga pemahaman menjadi lambat. Satu

siklus pelatihan yang melibatkan semua pola disebut *epoch*.

Pemilihan bobot awal sangat mempengaruhi cepat tidaknya proses pelatihan menuju kekonvergenan. Apabila bobot awal terlalu besar maka masukan ke setiap lapisan tersembunyi atau lapisan keluaran akan jatuh pada daerah dimana turunan fungsi aktivasinya akan sangat kecil. Apabila bobot awal terlalu kecil, maka masukan ke setiap lapisan tersembunyi atau lapisan keluaran akan sangat kecil. Hal ini akan menyebabkan proses pelatihan berjalan sangat lambat. Biasanya bobot awal diinisialisasi secara random.

Setelah pelatihan selesai dilakukan, jaringan dapat dipakai untuk pengujian model. Dalam hal ini, hanya propagasi maju (langkah 5 dan 6) saja yang dipakai untuk menentukan keluaran jaringan.

Contoh 2.4.1. Misal terdapat model jaringan yang terdiri dari 1 lapisan tersembunyi, dimana jumlah neuron pada masing-masing lapisan adalah 3 : 2 : 1 seperti pada gambar 2.6 lengkap dengan bobotnya.



Gambar 2.6: Model Jaringan Contoh 2.4.1

Tabel berikut merupakan 2 data pelatihan. Fungsi aktivasinya adalah sigmoid biner.

$$f(s) = \frac{1}{1+e^{-s}} \Rightarrow f'(s) = \frac{e^{-s}}{(1+e^{-s})^2}$$

Tabel 2.1: Data Pelatihan

No	x_1	x_2	x_3	d
1	0	0	0	1
2	0	1	0	0

Untuk $\gamma = 0.25$:

Pelatihan 1

Feed-forward

hidden $s_1 = 1 * 0 + 0 * 0 + (-1) * 0 + 1 = 1$

$$s_2 = 0 * 0 + 1 * 0 + 1 * 0 + 1 = 1$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = y_1 = 0.731$$

output $s = 0 * 0.731 + 1 * 0.731 + 1 = 1.731$

$$z = f(s) = \frac{1}{1+e^{-1.731}} = 0.850$$

Back-propagation

output $\delta_o = (d - z)f'(s) = (1 - 0.850) \frac{e^{-1.731}}{(1+e^{-1.731})^2} = 0.019$

$$\Delta w_{11} = \gamma \delta y_1 = 0.25 * (0.019) * 0.731 = 0.004$$

$$\Delta w_{21} = \gamma \delta y_2 = 0.25 * (0.019) * 0.731 = 0.004$$

$$w_{11}(\text{baru}) = 0 + (0.004) = 0.004$$

$$w_{21}(\text{baru}) = 1 + (0.004) = 1.004$$

hidden $\delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [0.019(0.004 + 1.004)] = 0.004$

$$s_2 = s_1 \Rightarrow \delta_2 = \delta_1 = 0.004$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.5 * (0.004) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.5 * (0.004) * 0 = 0$$

$$x_1 = x_2 = x_3 \Rightarrow \Delta w_{21} = \Delta w_{22} = \Delta w_{31} = \Delta w_{32} = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + 0 = 0$$

$$w_{22}(\text{baru}) = 1 + 0 = 1$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

Pelatihan 2

Feed-forward

hidden $s_1 = 1 * 0 + 0 * 1 + (-1) * 0 + 1 = 1$

$$s_2 = 0 * 0 + 1 * 1 + 1 * 0 + 1 = 2$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = f(s_2) = \frac{1}{1+e^{-2}} = 0.881$$

output $s = (0.004) * 0.731 + 1.004 * 0.881 + 1 = 1.886$

$$z = f(s) = \frac{1}{1+e^{-1.886}} = 0.868$$

Back-propagation

output $\delta_o = (d - z)f'(s) = (0 - 0.868) \frac{e^{-1.886}}{(1+e^{-1.886})^2} = -0.099$

$$\Delta w_{11} = \gamma \delta_o y_1 = 0.25 * (-0.099) * 0.731 = -0.018$$

$$\Delta w_{21} = 0.25 * (-0.099) * 0.881 = -0.022$$

$$w_{11}(\text{baru}) = 0.004 + (-0.018) = -0.015$$

$$w_{21}(\text{baru}) = 1.004 + (-0.022) = 0.982$$

hidden $\delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [-0.099(-0.015 + 0.982)] = -0.019$

$$\delta_2 = f'(s_2) \sum \delta_o w_{ko} = \frac{e^{-2}}{(1+e^{-2})^2} [-0.099(-0.015 + 0.982)] = -0.010$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.25 * (-0.019) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.25 * (-0.010) * 0 = 0$$

$$\Delta w_{21} = \gamma \delta_1 x_2 = 0.25 * (-0.019) * 1 = -0.005$$

$$\Delta w_{22} = \gamma \delta_2 x_2 = 0.25 * (-0.010) * 1 = -0.003$$

$$\Delta w_{31} = \gamma \delta_1 x_3 = 0.25 * (-0.019) * 0 = 0$$

$$\Delta w_{32} = \gamma \delta_2 x_3 = 0.5 * (-0.010) * 0 = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + (-0.005) = -0.005$$

$$w_{22}(\text{baru}) = 1 + (-0.003) = 0.997$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

Untuk $\gamma = 0.5$:

Pelatihan 1

Feed-forward

hidden $s_1 = 1 * 0 + 0 * 0 + (-1) * 0 + 1 = 1$

$$s_2 = 0 * 0 + 1 * 0 + 1 * 0 + 1 = 1$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = y_1 = 0.731$$

output $s = 0 * 0.731 + 1 * 0.731 + 1 = 1.731$

$$z = f(s) = \frac{1}{1+e^{-1.731}} = 0.850$$

Back-propagation

output $\delta_o = (d - z)f'(s) = (1 - 0.850) \frac{e^{-1.731}}{(1+e^{-1.731})^2} = 0.019$

$$\Delta w_{11} = \gamma \delta y_1 = 0.5 * (0.019) * 0.731 = 0.007$$

$$\Delta w_{21} = \gamma \delta y_2 = 0.5 * (0.019) * 0.731 = 0.007$$

$$w_{11}(\text{baru}) = 0 + (0.007) = 0.007$$

$$w_{21}(\text{baru}) = 1 + (0.007) = 1.007$$

$$\text{hidden } \delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [0.019(0.007 + 1.007)] = 0.004$$

$$s_2 = s_1 \Rightarrow \delta_2 = \delta_1 = 0.004$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.5 * (0.004) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.5 * (0.004) * 0 = 0$$

$$x_1 = x_2 = x_3 \Rightarrow \Delta w_{21} = \Delta w_{22} = \Delta w_{31} = \Delta w_{32} = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + 0 = 0$$

$$w_{22}(\text{baru}) = 1 + 0 = 1$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

Pelatihan 2

Feed-forward

$$\text{hidden } s_1 = 1 * 0 + 0 * 1 + (-1) * 0 + 1 = 1$$

$$s_2 = 0 * 0 + 1 * 1 + 1 * 0 + 1 = 2$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = f(s_2) = \frac{1}{1+e^{-2}} = 0.881$$

$$\text{output } s = (0.007) * 0.731 + 1.007 * 0.881 + 1 = 1.892$$

$$z = f(s) = \frac{1}{1+e^{-1.892}} = 0.869$$

Back-propagation

$$\text{output } \delta_o = (d - z)f'(s) = (0 - 0.869) \frac{e^{-1.892}}{(1+e^{-1.892})^2} = -0.099$$

$$\Delta w_{11} = \gamma \delta_o y_1 = 0.5 * (-0.099) * 0.731 = -0.036$$

$$\Delta w_{21} = 0.5 * (-0.099) * 0.881 = -0.044$$

$$w_{11}(\text{baru}) = 0.007 + (-0.036) = -0.029$$

$$w_{21}(\text{baru}) = 1.007 + (-0.044) = 0.963$$

$$\text{hidden } \delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [-0.099(-0.029 + 0.963)] = -0.018$$

$$\delta_2 = f'(s_2) \sum \delta_o w_{ko} = \frac{e^{-2}}{(1+e^{-2})^2} [-0.099(-0.029 + 0.963)] = -0.010$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.5 * (-0.018) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.5 * (-0.010) * 0 = 0$$

$$\Delta w_{21} = \gamma \delta_1 x_2 = 0.5 * (-0.018) * 1 = -0.009$$

$$\Delta w_{22} = \gamma \delta_2 x_2 = 0.5 * (-0.010) * 1 = -0.005$$

$$\Delta w_{31} = \gamma \delta_1 x_3 = 0.5 * (-0.018) * 0 = 0$$

$$\Delta w_{32} = \gamma \delta_2 x_3 = 0.5 * (-0.010) * 0 = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + (-0.009) = -0.009$$

$$w_{22}(\text{baru}) = 1 + (-0.005) = 0.995$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

Untuk $\gamma = 0.75$:

Pelatihan 1

Feed-forward

$$\text{hidden } s_1 = 1 * 0 + 0 * 0 + (-1) * 0 + 1 = 1$$

$$s_2 = 0 * 0 + 1 * 0 + 1 * 0 + 1 = 1$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = y_1 = 0.731$$

output $s = 0 * 0.731 + 1 * 0.731 + 1 = 1.731$

$$z = f(s) = \frac{1}{1+e^{-1.731}} = 0.850$$

Back-propagation

output $\delta_o = (d - z)f'(s) = (1 - 0.850)\frac{e^{-1.731}}{(1+e^{-1.731})^2} = 0.019$

$$\Delta w_{11} = \gamma \delta y_1 = 0.75 * (0.019) * 0.731 = 0.011$$

$$\Delta w_{21} = \gamma \delta y_2 = 0.75 * (0.019) * 0.731 = 0.011$$

$$w_{11}(\text{baru}) = 0 + (0.011) = 0.011$$

$$w_{21}(\text{baru}) = 1 + (0.011) = 1.011$$

hidden $\delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [0.019(0.011 + 1.011)] = 0.004$

$$s_2 = s_1 \Rightarrow \delta_2 = \delta_1 = 0.004$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.75 * (0.019) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.75 * (-0.019) * 0 = 0$$

$$x_1 = x_2 = x_3 \Rightarrow \Delta w_{21} = \Delta w_{22} = \Delta w_{31} = \Delta w_{32} = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + 0 = 0$$

$$w_{22}(\text{baru}) = 1 + 0 = 1$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

Pelatihan 2

Feed-forward

hidden $s_1 = 1 * 0 + 0 * 1 + (-1) * 0 + 1 = 1$

$$s_2 = 0 * 0 + 1 * 1 + 1 * 0 + 1 = 2$$

$$y_1 = f(s_1) = \frac{1}{1+e^{-1}} = 0.731$$

$$y_2 = f(s_2) = \frac{1}{1+e^{-2}} = 0.881$$

output $s = (0.011) * 0.731 + 1.011 * 0.881 + 1 = 1.898$

$$z = f(s) = \frac{1}{1+e^{-1.898}} = 0.870$$

Back-propagation

output $\delta_o = (d - z)f'(s) = (0 - 0.870)\frac{e^{-1.898}}{(1+e^{-1.898})^2} = -0.099$

$$\Delta w_{11} = \gamma \delta y_1 = 0.75 * (-0.099) * 0.731 = -0.054$$

$$\Delta w_{21} = 0.75 * (-0.099) * 0.881 = -0.065$$

$$w_{11}(\text{baru}) = 0.011 + (-0.054) = -0.044$$

$$w_{21}(\text{baru}) = 1.011 + (-0.065) = 0.945$$

hidden $\delta_1 = f'(s_1) \sum \delta_o w_{ko} = \frac{e^{-1}}{(1+e^{-1})^2} [-0.099(-0.044 + 0.945)] = -0.017$

$$\delta_2 = f'(s_2) \sum \delta_o w_{ko} = \frac{e^{-2}}{(1+e^{-2})^2} [-0.099(-0.044 + 0.945)] = -0.009$$

$$\Delta w_{11} = \gamma \delta_1 x_1 = 0.75 * (-0.017) * 0 = 0$$

$$\Delta w_{12} = \gamma \delta_2 x_1 = 0.75 * (-0.009) * 0 = 0$$

$$\Delta w_{21} = \gamma \delta_1 x_2 = 0.75 * (-0.017) * 1 = -0.013$$

$$\Delta w_{22} = \gamma \delta_2 x_2 = 0.75 * (-0.009) * 1 = -0.007$$

$$\Delta w_{31} = \gamma \delta_1 x_3 = 0.75 * (-0.017) * 0 = 0$$

$$\Delta w_{32} = \gamma \delta_2 x_3 = 0.75 * (-0.009) * 0 = 0$$

$$w_{11}(\text{baru}) = 1 + 0 = 1$$

$$w_{12}(\text{baru}) = 0 + 0 = 0$$

$$w_{21}(\text{baru}) = 0 + (-0.013) = -0.013$$

$$w_{22}(\text{baru}) = 1 + (-0.007) = 0.993$$

$$w_{31}(\text{baru}) = 1 + 0 = 1$$

$$w_{32}(\text{baru}) = 1 + 0 = 1$$

2.5 Transformasi Data

Transformasi data dilakukan agar kestabilan sebaran data dicapai. Selain itu berguna untuk menyesuaikan nilai data dengan range fungsi aktivasi yang digunakan dalam jaringan. Ada beberapa transformasi yang digunakan, yaitu transformasi polinomial, transformasi normal dan transformasi linear. Nilai hasil transformasi polinomial, normal dan linear dapat diperoleh dengan persamaan sebagai berikut.

- Transformasi Polinomial

$$x' = \ln x \quad (2.15)$$

Dimana:

x' : nilai data setelah transformasi polinomial

x : nilai data aktual

- Transformasi Normal (Normalisasi)

$$x_n = \frac{x_0 - x_{min}}{x_{maks} - x_{min}} \quad (2.16)$$

Dimana:

x_n : nilai data normal

x_0 : nilai data aktual

x_{min} : nilai minimum data aktual keseluruhan

x_{maks} : nilai maksimum data aktual keseluruhan

- Transformasi Linear pada selang $[a, b]$

$$x' = \frac{(x - x_{min})(b - a)}{x_{maks} - x_{min}} + a \quad (2.17)$$

Dimana:

x' : nilai data setelah transformasi polinomial

x : nilai data aktual

x_{min} : nilai minimum data aktual keseluruhan

x_{maks} : nilai maksimum data aktual keseluruhan

2.6 Akurasi Model

Model jaringan yang dibangun akan dinilai keakuratan prakiraannya. Keakuratan prakiraan model tersebut dilihat berdasarkan nilai *error*nya.

$$E_{pelatihan} = \frac{1}{N} \sum_{i=1}^N E_p \quad (2.18)$$

N merupakan banyaknya *epoch* dalam pelatihan dan E_p merupakan *error* pada satu *epoch* yang didefinisikan sebagai berikut:

$$E_p = \frac{1}{2} \sum_{i=1}^n (t_i - o_i)^2 \quad (2.19)$$

Dimana:

n : banyaknya data pelatihan

t_i : target (nilai aktual yang telah di transformasi) pada waktu i

o_i : hasil keluaran (nilai ramalan) pada waktu i

Langkah terakhir dalam proses pembangunan model adalah pengujian

model. Pengujian model (*testing*) biasanya berupa pengecekan model terhadap data bebas. Tujuannya adalah memeriksa apakah model yang dikembangkan dari data sebelumnya masih dapat diterapkan kepada data baru atau tidak. Pada proses ini, model yang dihasilkan pada proses pelatihan tersebut digunakan untuk memprakirakan setiap kasus pada data baru, yaitu dengan dilakukannya proses perambatan maju (*feed-forward*), sehingga diperoleh hasil prakiraan. Kemudian dihitung $E_{pengujian}$ berdasarkan hasil prakiraan dan target dengan rumus:

$$E_{pengujian} = \frac{1}{M} \frac{1}{2} \sum_{i=1}^M (t_i - o_i)^2 \quad (2.20)$$

M merupakan banyaknya data pengujian.

BAB III

PEMBAHASAN

3.1 Data Yang Diamati

Dalam skripsi ini, data yang akan diamati adalah data Badan Meteorologi Klimatologi dan Geofisika (BMKG) Stasiun Meteorologi Banyuwangi, Jawa Timur. Sumber data merupakan data sekunder yaitu data yang sudah ada berupa dokumen, arsip, informasi, fakta tertulis, dan lainnya.

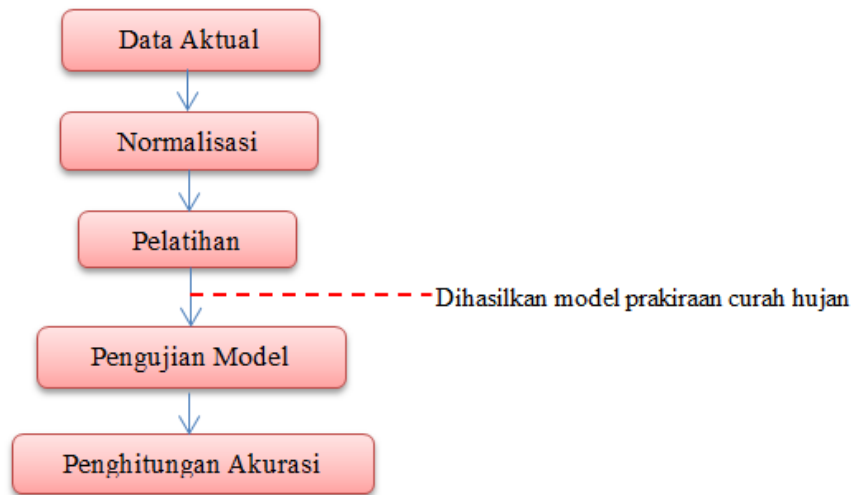
Data tersebut terdiri dari suhu udara, kelembapan udara, tekanan udara, dan curah hujan. Suhu udara yang digunakan merupakan rata-rata suhu udara bulanan dalam satuan Celcius. Kelembapan udara yang digunakan merupakan rata-rata kelembapan udara bulanan dalam satuan %. Tekanan udara yang digunakan merupakan rata-rata tekanan udara bulanan dalam satuan milibar (mb). Curah hujan yang digunakan merupakan jumlah curah hujan selama satu bulan dalam satuan milimeter (mm).

3.2 Prosedur Pengolahan Data

Data dalam percobaan ini diolah dengan prosedur (langkah-langkah) sebagai berikut:

1. Proses normalisasi

Sebelum dilakukan pelatihan, data aktual suhu udara, kelembapan udara,



Gambar 3.1: Diagram Prosedur Pengolahan Data

tekanan udara, dan curah hujan ditransformasi terlebih dahulu menggunakan transformasi normal dengan rumus sebagai berikut.

$$x_n = \frac{x_0 - x_{min}}{x_{maks} - x_{min}}$$

Dimana:

x_n : nilai data normal

x_0 : nilai data aktual

x_{min} : nilai minimum data aktual keseluruhan

x_{maks} : nilai maksimum data aktual keseluruhan.

Data hasil normalisasi tersebut dikelompokkan menjadi 2, yaitu

- suhu udara, kelembapan udara, dan tekanan udara sebagai data masukan;
- curah hujan sebagai data target.

2. Proses pelatihan

Konfigurasi jaringan yang digunakan dalam percobaan ini terdiri dari 3 lapisan, yaitu lapisan masukan, 1 lapisan tersembunyi, dan lapisan keluaran. Lapisan masukan terdiri dari 3 simpul, yaitu suhu udara, kelembapan udara, dan tekanan udara. Kemudian lapisan tersembunyi terdiri dari 7 simpul, karena untuk n jumlah simpul pada lapisan masukan, maka jumlah simpul pada lapisan tersembunyi adalah $2n + 1$, dimana n merupakan banyaknya simpul pada lapisan masukan (Vamsidhar, 2010). Lapisan keluaran terdiri dari 1 simpul, karena target yang diinginkan hanya 1 yaitu curah hujan.

Untuk mendapatkan nilai pada tiap simpul pada lapisan tersembunyi, setiap data masukan dikenakan fungsi aktivasi. Fungsi aktivasi yang digunakan adalah sigmoid. $f(s) = \frac{1}{1+e^{-s}}$. Demikian pula pada lapisan keluaran. Nilai yang dihasilkan pada lapisan keluaran bukanlah curah hujan aktual, melainkan curah hujan yang sudah ternormalisasi. Jadi, untuk mendapatkan curah hujan aktual, lakukan kebalikan dari proses normalisasi.

Model jaringan yang telah dipaparkan di atas dapat dilihat pada gambar 3.2.

Dimana:


x_1 : suhu udara

x_2 : kelembapan udara

x_3 : tekanan udara

3. Proses pengujian model

Setelah dilakukan proses pelatihan, model yang diperoleh akan diuji terhadap data baru. Model yang dihasilkan pada proses pelatihan tersebut di-



Gambar 3.2: Model Jaringan

gunakan untuk memprakirakan setiap kasus pada data baru, yaitu dengan dilakukannya proses perambatan maju (*feed-forward*), sehingga diperoleh hasil prakiraan.

4. Penghitungan akurasi

Dari hasil prakiraan, akurat atau tidaknya model dapat dilihat dari nilai *error*nya. Untuk mengetahui keakuratan model pada proses pelatihan dan pengujian dapat dihitung dengan rumus sebagai berikut:

$$E_{\text{pelatihan}} = \frac{1}{N} \sum_{i=1}^N E_p$$

N merupakan banyaknya epoch dalam pelatihan dan E_p merupakan *error*

pada satu epoch yang didefinisikan sebagai berikut:

$$E_p = \frac{1}{2} \sum_{i=1}^n (t_i - o_i)^2$$

Dimana:

n : banyaknya data pelatihan

t_i : target (nilai aktual yang telah di transformasi) pada waktu i

o_i : hasil keluaran (nilai ramalan) pada waktu i

$$E_{pengujian} = \frac{1}{M} \frac{1}{2} \sum_{i=1}^M (t_i - o_i)^2$$

M merupakan banyaknya data pengujian.

3.3 Hasil Pengolahan Data

Berdasarkan prosedur pengolahan data pada subbab 3.2, yang pertama dilakukan adalah menormalisasikan data aktual. Kemudian data hasil normalisasi tersebut dikelompokkan menjadi 3, yaitu: data pelatihan 90% dan data pengujian 10%. Semua proses dilakukan menggunakan MATLAB R2014a dan hasil yang diperoleh sebagai berikut.

Dilakukan sembilan percobaan, yaitu prakiraan curah hujan untuk 1 bulan, 2 bulan, 3 bulan, 4 bulan, 5 bulan, 6 bulan, 9 bulan, 12 bulan dan 18 bulan ke depan, yang hasilnya adalah sebagai berikut:

3.3.1 Model prakiraan curah hujan 1 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 1 bulan ke depan adalah 119. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} -8.4997 & 6.5140 & -0.1957 \\ 4.4514 & 5.5328 & -7.1740 \\ -1.1934 & 2.8813 & 10.7510 \\ -0.5463 & -8.8310 & 6.0098 \\ 9.3218 & -4.8762 & 1.0033 \\ 3.0377 & 10.1855 & -0.7147 \\ 2.0288 & -7.7364 & -7.2521 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} 6.4439 \\ -6.6795 \\ -7.2610 \\ 1.8473 \\ 1.7195 \\ -2.5889 \\ 11.7286 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} -0.1354 & -1.8388 & -2.6565 & -0.0905 & -1.6214 & 0.1978 & 1.2323 \end{pmatrix}$$

$$\text{dan biasnya} = \begin{pmatrix} 0.6188 \end{pmatrix}$$

Salah satu perhitungan pada proses pengujian adalah sebagai berikut:

Lapisan tersembunyi

$$\text{Masukan} = \begin{pmatrix} 0.7619 & 0.5833 & 0.2958 \end{pmatrix}$$

$$s_k = \begin{pmatrix} 0.7619 & 0.5833 & 0.2958 \end{pmatrix} \begin{pmatrix} -8.4997 & 6.5140 & -0.1957 \\ 4.4514 & 5.5328 & -7.1740 \\ -1.1934 & 2.8813 & 10.7510 \\ -0.5463 & -8.8310 & 6.0098 \\ 9.3218 & -4.8762 & 1.0033 \\ 3.0377 & 10.1855 & -0.7147 \\ 2.0288 & -7.7364 & -7.2521 \end{pmatrix}^T + \begin{pmatrix} 6.4439 \\ -6.6795 \\ -7.2610 \\ 1.8473 \\ 1.7195 \\ -2.5889 \\ 11.7286 \end{pmatrix}^T$$

$$= \begin{pmatrix} 3.7099 & -2.1824 & -3.3096 & -1.9428 & 6.2741 & 5.4557 & 6.6165 \end{pmatrix}$$

Nilai masing-masing node pada lapisan tersembunyi adalah

$$y_k = f(s_k) = \frac{1}{1+e^{-s_k}} = \begin{pmatrix} 0.9761 & 0.1013 & 0.0352 & 0.1253 & 0.9981 & 0.9957 & 0.9987 \end{pmatrix}$$

Lapisan keluaran

$$s = \begin{pmatrix} 0.9761 & 0.1013 & 0.0352 & 0.1253 & 0.9981 & 0.9957 & 0.9987 \end{pmatrix} \begin{pmatrix} -0.1354 \\ -1.8388 \\ -2.6565 \\ -0.0905 \\ -1.6214 \\ 0.1978 \\ 1.2323 \end{pmatrix}$$

$$= 0.0043$$

$$z = f(s) = \frac{1}{1+e^{-s}} = 0.5011$$

Kemudian dilakukan kebalikan dari proses normalisasi, yaitu sebagai berikut:

$$x_0 = x_n * (x_{maks} - x_{min}) + x_{min}$$

$$x_{min} = 0, x_{maks} = 352.8, x_n = z = 0.5011$$

$$x_0 = 0.5011 * (352.8 - 0) + 0 = 176.8040$$

Sehingga diperoleh hasil prakiraannya yaitu 176.8040.

Pada setiap data pengujian dilakukan juga proses yang sama seperti diatas, untuk memperoleh hasil prakiraannya. Berikut merupakan target (data aktual) dan hasil prakiraan pada proses pengujian:

Tabel 3.1: Proses Pengujian Model Prakiraan Curah Hujan 1 Bulan Ke Depan

Target	Hasil Prakiraan
527.5	176.8040
100.2	148.2209
193.1	138.9183
228.8	159.6195
97.3	113.2389
122.8	154.9147
156.0	23.0633
37.3	22.3686
6.9	27.2945
0.8	30.5737
237.6	183.7616
160.3	183.3112

3.3.2 Model prakiraan curah hujan 2 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 2 bulan ke depan adalah 118. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} 6.4038 & -1.0392 & 9.2575 \\ -7.9921 & -1.6944 & 6.9472 \\ 2.8614 & 6.0756 & -8.3629 \\ 0.8815 & -10.2351 & -2.1293 \\ 7.3758 & -7.0829 & -0.1162 \\ 4.1832 & -9.4490 & -1.9040 \\ 8.9145 & -3.0882 & 5.0586 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -11.5338 \\ 4.5998 \\ -2.3528 \\ 6.6896 \\ -0.4535 \\ 7.5449 \\ 0.3667 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} 1.4229 & -0.9773 & 0.7590 & -1.7844 & 2.8097 & -1.0118 & -2.4237 \end{pmatrix}$$

$$\text{dan biasnya} = \begin{pmatrix} 2.6307 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Tabel 3.2: Proses Pengujian Model Prakiraan Curah Hujan 2 Bulan Ke Depan

Target	Hasil Prakiraan
527.5	146.8443
100.2	181.8431
193.1	137.9836
228.8	137.8215
97.3	120.5687
122.8	119.4806
156.0	121.5388
37.3	116.8421
6.9	66.9062
0.8	36.6850
237.6	96.8761
160.3	141.4317

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.3 Model prakiraan curah hujan 3 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 3 bulan ke depan adalah 117. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} -4.2611 & 7.0499 & -6.8879 \\ -7.1622 & -5.5839 & 5.2173 \\ -0.3149 & -3.9053 & 10.0083 \\ -9.7248 & 3.1956 & 1.7308 \\ 7.3052 & 7.1755 & 3.1933 \\ 9.6693 & -1.8862 & 3.8853 \\ -6.4992 & 7.3290 & -4.6328 \end{pmatrix} \text{ dan biasanya} = \begin{pmatrix} 6.0710 \\ 7.5191 \\ 0.5391 \\ 2.6910 \\ -7.0355 \\ -2.4684 \\ -3.1194 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} -1.9107 & 1.2856 & -1.2522 & -0.7269 & -0.1410 & 1.8339 & 1.4876 \end{pmatrix}$$

$$\text{dan biasanya} = \begin{pmatrix} -0.2905 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Tabel 3.3: Proses Pengujian Model Prakiraan Curah Hujan 3 Bulan Ke Depan

Target	Hasil Prakiraan
527.5	212.2028
100.2	187.3126
193.1	107.9333
228.8	104.0120
97.3	120.1095
122.8	108.4387
156.0	101.5971
37.3	96.6063
6.9	76.7983
0.8	77.3079
237.6	102.9570
160.3	192.1455

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.4 Model prakiraan curah hujan 4 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 4 bulan ke depan adalah 116. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} -9.0911 & -3.7611 & -3.3402 \\ -4.2585 & -9.6993 & 2.3964 \\ -2.2229 & -1.6730 & -10.5684 \\ 9.6744 & -0.4978 & -4.4352 \\ -7.3588 & -7.5165 & 2.0283 \\ 8.8211 & 2.0622 & -5.5932 \\ 3.4803 & -6.5173 & 7.6514 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} 13.9697 \\ 8.7318 \\ 8.9043 \\ -2.8710 \\ 4.0089 \\ 1.1449 \\ 3.0386 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} 1.9281 & 0.6718 & -2.1883 & 1.1492 & 0.6876 & 0.8252 & 1.1413 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -4.2393 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.5 Model prakiraan curah hujan 5 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 5 bulan ke depan adalah 115. Setelah dilakukan pelatihan, diperoleh

Tabel 3.4: Proses Pengujian Model Prakiraan Curah Hujan 4 Bulan Ke Depan

Target	Hasil Prakiraan
527.5	190.0037
100.2	188.0688
193.1	162.8696
228.8	89.6557
97.3	44.4468
122.8	135.6741
156.0	102.9133
37.3	117.3698
6.9	75.3512
0.8	115.6389
237.6	156.1239
160.3	168.4661

modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} 7.6028 & 0.5978 & -7.3737 \\ -4.3227 & -2.3354 & 9.4321 \\ -6.7740 & 7.1971 & -3.9849 \\ -8.7931 & 0.6136 & 6.0325 \\ -6.8836 & 6.8987 & 3.0144 \\ -4.7029 & 2.9406 & -9.3086 \\ -1.4068 & 8.9167 & -4.9905 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -6.1559 \\ 1.6629 \\ 4.1734 \\ 0.6317 \\ -5.5971 \\ 1.7795 \\ -7.1128 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} -1.9115 & 0.5390 & -2.0686 & 1.5862 & 1.1731 & 1.4671 & -3.1162 \end{pmatrix} \text{ dan} \\ \text{biasnya} = \begin{pmatrix} -0.6875 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan

Tabel 3.5: Proses Pengujian Model Prakiraan Curah Hujan 5 Bulan Ke Depan

Target	Hasil Prakiraan
527.5	180.6015
100.2	233.4155
193.1	211.6325
228.8	139.7717
97.3	29.8730
122.8	27.2670
156.0	71.6819
37.3	44.3818
6.9	48.4137
0.8	34.2701
237.6	116.3283
160.3	165.0344

curah hujan 1 bulan ke depan.

3.3.6 Model prakiraan curah hujan 6 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 6 bulan ke depan adalah 114. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} -4.1680 & 3.4969 & -9.0613 \\ -6.7752 & 0.9463 & -7.7458 \\ 9.0462 & 4.6002 & -1.9081 \\ 9.8793 & 1.3123 & -3.9350 \\ -0.4616 & 9.9535 & -3.2268 \\ 3.6087 & -7.3365 & 6.9354 \\ 1.1260 & -10.2644 & 3.1021 \end{pmatrix} \text{ dan biasanya} = \begin{pmatrix} 10.5127 \\ 11.0479 \\ -8.2741 \\ -4.2817 \\ -5.6681 \\ 1.9745 \\ 8.0603 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

Bobotnya = $\begin{pmatrix} 1.0550 & 1.7603 & 2.2773 & -2.7631 & -1.5953 & 0.9349 & -2.7431 \end{pmatrix}$ dan biasanya = $\begin{pmatrix} -1.1924 \end{pmatrix}$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Tabel 3.6: Proses Pengujian Model Prakiraan Curah Hujan 6 Bulan Ke Depan

Target	Hasil Prakiraan
100.2	166.7627
193.1	97.2049
228.8	96.8611
97.3	39.3233
122.8	84.1040
156.0	76.2124
37.3	75.8497
6.9	79.7129
0.8	84.7929
237.6	65.0366
160.3	159.4159

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.7 Model prakiraan curah hujan 9 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 9 bulan ke depan adalah 111. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} 0.6514 & 0.2951 & -10.6514 \\ 1.9703 & -9.8492 & -3.7580 \\ 5.9029 & -7.6253 & 2.8658 \\ -1.0747 & 6.1169 & -8.7777 \\ -3.7242 & -7.2419 & 7.1913 \\ 4.1010 & -8.7515 & -1.2970 \\ 6.5479 & 6.9094 & 4.9530 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -1.6778 \\ 2.2607 \\ -5.3698 \\ 1.9564 \\ -0.6698 \\ 8.9900 \\ -3.8055 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} 0.8788 & -0.5201 & -2.9554 & -1.7959 & -1.9798 & -0.7452 & -3.0666 \end{pmatrix}$$

$$\text{dan biasnya} = \begin{pmatrix} 4.0548 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Tabel 3.7: Proses Pengujian Model Prakiraan Curah Hujan 9 Bulan Ke Depan

Target	Hasil Prakiraan
100.2	155.6318
193.1	172.2795
228.8	145.2228
97.3	76.9892
122.8	56.1506
156.0	38.8357
37.3	89.7518
6.9	107.4078
0.8	98.3063
237.6	192.6394
160.3	142.8865

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.8 Model prakiraan curah hujan 12 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 12 bulan ke depan adalah 108. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} 8.3027 & 6.4846 & -1.6194 \\ -2.1502 & -3.6871 & 9.8319 \\ 6.8210 & -5.3890 & 5.9340 \\ -2.9623 & 7.0506 & -7.3605 \\ 3.7725 & 7.1460 & 6.0343 \\ -2.2334 & -3.8612 & 9.2660 \\ 9.1425 & 4.6286 & -0.5873 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -11.9862 \\ 1.3486 \\ -5.5383 \\ 1.8140 \\ -8.1590 \\ -6.4630 \\ -3.3045 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} 2.8957 & -0.5154 & -1.9054 & -0.9353 & -1.9886 & 0.1695 & 2.9436 \end{pmatrix}$$

$$\text{dan biasnya} = \begin{pmatrix} -1.2901 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

3.3.9 Model prakiraan curah hujan 18 bulan ke depan

Jumlah data yang diamati dalam membangun model prakiraan curah hujan untuk 18 bulan ke depan adalah 102. Setelah dilakukan pelatihan, diperoleh modelnya sebagai berikut:

Tabel 3.8: Proses Pengujian Model Prakiraan Curah Hujan 12 Bulan Ke Depan

Target	Hasil Prakiraan
100.2	219.8207
193.1	204.1861
228.8	65.2769
97.3	93.0014
122.8	90.8573
156.0	88.4058
37.3	17.4764
6.9	31.5998
0.8	66.5822
237.6	69.6994
160.3	152.5835

Lapisan masukan ke lapisan tersembunyi:

$$\text{Bobotnya} = \begin{pmatrix} 5.4856 & -0.3861 & 8.0322 \\ -4.5962 & -7.8886 & 5.2060 \\ 5.0470 & 0.7825 & 11.1936 \\ -7.0202 & -6.0308 & 5.3974 \\ -5.9814 & -6.8076 & 5.7582 \\ -5.6210 & 5.4788 & 7.5149 \\ 3.8992 & 1.6699 & -9.2477 \end{pmatrix} \text{ dan biasnya} = \begin{pmatrix} -13.6383 \\ 7.7164 \\ -5.9910 \\ 3.8217 \\ 1.6094 \\ -6.7456 \\ 8.6694 \end{pmatrix}$$

Lapisan tersembunyi ke lapisan keluaran:

$$\text{Bobotnya} = \begin{pmatrix} 2.3358 & 0.5669 & 2.1021 & -0.0731 & 0.5393 & 1.0151 & -0.9108 \end{pmatrix} \text{ dan} \\ \text{biasnya} = \begin{pmatrix} -3.3474 \end{pmatrix}$$

Setelah dilakukan kebalikan dari proses normalisasi, curah hujan yang dihasilkan pada proses pengujian adalah sebagai berikut:

Hasil prakiraan tersebut berdasarkan proses yang sama seperti pada prakiraan curah hujan 1 bulan ke depan.

Tabel 3.9: Proses Pengujian Model Prakiraan Curah Hujan 18 Bulan Ke Depan

Target	Hasil Prakiraan
193.1	240.5298
228.8	115.1464
97.3	81.6439
122.8	43.0085
156.0	32.3961
37.3	54.4713
6.9	30.7871
0.8	93.8547
237.6	106.3049
160.3	199.8096

Error kesembilan percobaan ini berbeda, nilai $E_{pengujian}$ masing-masing percobaan adalah sebagai berikut:


Tabel 3.10: Perbandingan prakiraan t-bulan ke depan

Prakiraan t-bulan ke depan	$E_{pengujian}$
1	0.0525
2	0.0755
3	0.0643
4	0.0689
5	0.0712
6	0.0140
9	0.0088
12	0.0132
18	0.0118

Berdasarkan tabel 3.10, model prakiraan untuk 9 bulan ke depan lebih baik dari model prakiraan yang lain karena memiliki nilai $E_{pengujian}$ terkecil. Nilai *error* prakiraan curah hujan untuk 9 bulan ke depan pada proses pelatihan dan pengujian secara berurut adalah 0.0278 dan 0.0088.

Dalam penelitian ini, dengan prosedur yang sama, juga dilakukan prakiraan curah hujan 9 bulan ke depan dengan 1 input, yaitu suhu. Sehingga kon-

figurasi jaringannya yaitu 1 simpul (suhu) pada lapisan masukan; 3 simpul pada lapisan tersembunyi ($2n+1$, $n=1$); 1 simpul (curah hujan) pada lapisan keluaran. Konfigurasi jaringannya dapat dilihat pada gambar 3.3.



Gambar 3.3: Model Jaringan 1 Input

Setelah dilakukan proses pelatihan dan pengujian menggunakan software MATLAB 2014a, diperoleh nilai *error*nya pada proses pelatihan dan pengujiannya yaitu sebesar 0.0328 dan 0.0114.

Tabel 3.11: Perbandingan banyaknya masukan

Banyaknya simpul masukan	$E_{pengujian}$
1	0.0114
3	0.0088

Berdasarkan tabel 3.11, model prakiraan curah hujan 9 bulan ke depan dengan tiga simpul masukan lebih baik daripada satu simpul masukan karena nilai $E_{pengujian}$ nya lebih kecil.

(Note: Setiap 1 kali pelatihan dapat menghasilkan model dan nilai *error* yang berbeda. Demikian pula untuk data yang berbeda.)

BAB IV

PENUTUP

4.1 Kesimpulan

Berdasarkan hasil pembahasan dapat disimpulkan bahwa:

1. Model prakiraan curah hujan yang terbaik, di Kabupaten Banyuwangi, berdasarkan nilai $E_{pengujian}$ nya adalah model prakiraan curah hujan untuk 9 bulan ke depan.
2. Dengan konfigurasi jaringan tiga simpul pada lapisan masukan yaitu suhu udara, kelembapan udara, dan tekanan udara; tujuh simpul pada lapisan tersembunyi; dan satu simpul pada lapisan keluaran yaitu curah hujan, nilai *error* model tersebut pada proses pelatihan ($E_{pelatihan}$) dan pengujian ($E_{pengujian}$) adalah 0.0278 dan 0.0088. Sementara itu konfigurasi satu simpul pada lapisan masukan yaitu suhu udara; tiga simpul pada lapisan tersembunyi; dan satu simpul masukan pada lapisan keluaran yaitu curah hujan, nilai *error* model tersebut pada proses pelatihan ($E_{pelatihan}$) dan pengujian ($E_{pengujian}$) adalah 0.0328 dan 0.0114. Jadi, model prakiraan curah hujan 9 bulan ke depan dengan tiga simpul masukan lebih baik daripada satu simpul masukan karena nilai $E_{pengujian}$ nya lebih kecil.

4.2 Saran

Sebaiknya mempertimbangkan faktor-faktor lain yang mungkin dapat mempengaruhi tingkat curah hujan di suatu daerah sehingga menghasilkan prakiraan curah hujan yang lebih akurat.

DAFTAR PUSTAKA

- Badan Meteorologi Klimatologi dan Geofisika. 2004-2013. Data Curah Hujan, Suhu Udara, Kelembapan Udara, dan Tekanan Udara. Jakarta: BMKG.
- Fausett, Laurene V. 1994. *Fundamentals Of Neural Networks Architectures, Algorithms and Applications*. Prentice-Hall. Tersedia di <http://www.csbdu.in/pdf/Fundamentals%20Of%20Neural%20Networks.pdf>
- Herjanto, Eddy. 2008. *Manajemen Operasi Edisi Ketiga*. Jakarta : Grasindo. Hal. 77-79
- Krse, Ben, dan Patrick van der Smagt. 1996. *An Introduction to Neural Neural Networks*. Eighth Edition. Hal. 33-37
- Lailani, Intan. 2006. Aplikasi Artificial Neural Network dengan Backpropagation dalam Peramalan Tingkat Suku Bunga Sertifikat Bank Indonesia (SBI). Skripsi. Jakarta: Universitas Negeri Jakarta.
- Nasution, Mulkan I. 2010. Analisis Pemetaan Validasi Prediksi Curah Hujan Dengan Model Jaringan Syaraf Tiruan Dan Wavelet Menggunakan Arc View 3.3. Tesis. Medan: Universitas Sumatera Utara.
- Vamsidhar, Enireddy, dkk. 2010. "Prediction of Rainfall Using Backpropagation Neural Network Model". International Journal on Computer Science and Engineering. Vol. 02, No. 04, Hal. 1119-1121
- W, Anugerah P. S. 2007. Perbandingan Jaringan Syaraf Tiruan Backpropagation

Dan Metode Deret Berkala Box-Jenkins (ARIMA) sebagai Metode Peramalan Curah Hujan. Skripsi. Semarang: Universitas Negeri Semarang.

Yuniar, Risty J., dkk. 2013. "Perbaikan Metode Prakiraan Cuaca Bandara Abdulrahman Saleh dengan Algoritma Neural Network Backpropagation". Jurnal EECCIS. Vol. 7, No. 1, Hal. 65-70

LAMPIRAN

LAMPIRAN 1

Data Aktual

Tabel 4.1: Suhu Udara, Kelembapan Udara, Tekanan Udara, dan Curah Hujan Bulanan Tahun 2004 - 2013

No.	Tahun	Bulan	Suhu	Kelembapan	Tekanan	Curah Hujan
1	2004	Januari	27.6	81	1010.1	191.2
2		Februari	27.1	83	1009.3	352.8
3		Maret	27.1	83	1009.3	305.7
4		April	28.2	79	1010.4	255.9
5		Mei	27.3	81	1010.0	209.5
6		Juni	26.2	76	1012.4	4.4
7		Juli	25.8	79	1011.6	3.5
8		Agustus	25.8	79	1013.0	32.2
9		September	26.3	80	1013.7	49.6
10		Oktober	27.9	74	1013.2	0.0
11		November	28.8	75	1010.9	44.4
12		Desember	28.1	77	1009.6	114.5
13	2005	Januari	28.8	75	1009.1	69.6
14		Februari	28.0	76	1010.1	174.4
15		Maret	27.9	79	1009.9	171.5
16		April	27.6	79	1011.4	128.7
17		Mei	27.4	77	1011.5	18.1
18		Juni	27.2	80	1010.9	42.5
19		Juli	26.5	76	1011.8	45.9
20		Agustus	25.8	78	1012.2	93.9
21		September	26.9	76	1012.2	1.5
22		Oktober	27.7	78	1012.0	81.9
23		November	28.4	73	1011.2	134.4
24		Desember	26.8	84	1008.7	328.8
25	2006	Januari	26.9	83	1008.6	157.7
26		Februari	27.2	80	1008.9	235.8
27		Maret	27.0	82	1008.7	284.1
28		April	27.6	79	1008.9	68.2

No.	Tahun	Bulan	Suhu	Kelembapan	Tekanan	Curah Hujan
29	2006	Mei	27.2	80	1010.6	146.6
30		Juni	25.8	81	1011.8	79.2
31		Juli	25.0	82	1013.1	61.2
32		Agustus	25.1	79	1013.0	4.6
33		September	25.7	77	1013.0	1.5
34		Oktober	27.5	74	1012.8	52.7
35		November	28.9	74	1010.4	6.9
36		Desember	28.8	76	1008.8	149.3
37	2007	Januari	27.8	76	1010.2	193.8
38		Februari	27.5	80	1010.2	250.2
39		Maret	26.7	84	1008.6	317.4
40		April	27.9	81	1010.3	177.7
41		Mei	27.7	80	1011.6	25.3
42		Juni	26.6	83	1010.3	114.6
43		Juli	25.6	79	1013.2	17.2
44		Agustus	25.5	80	1013.4	70.1
45		September	26.4	75	1013.1	116.8
46		Oktober	28.1	75	1012.1	12.9
47		November	28.6	75	1010.4	60.3
48	Desember	28.3	77	1008.1	103.5	
49	2008	Januari	27.7	78	1009.1	144.9
50		Februari	26.9	83	1008.1	278.4
51		Maret	27.0	81	1009.3	259.4
52		April	27.9	78	1009.8	34.0
53		Mei	27.3	78	1011.7	32.9
54		Juni	26.5	80	1012.5	11.7
55		Juli	25.6	79	1013.2	17.2
56		Agustus	26.0	83	1012.9	8.7
57		September	27.0	77	1013.1	26.2
58		Oktober	28.4	79	1012.0	82.1
59		November	28.2	80	1009.5	97.8
60		Desember	27.2	81	1008.9	255.0
61	2009	Januari	27.3	80	1009.4	291.9
62		Februari	27.0	82	1008.1	278.2
63		Maret	27.8	78	1010.5	57.1
64		April	28.6	77	1010.7	187.0

No.	Tahun	Bulan	Suhu	Kelembapan	Tekanan	Curah Hujan
65	2009	Mei	27.6	81	1010.5	107.0
66		Juni	27.0	78	1012.4	28.6
67		Juli	26.3	79	1013.3	60.3
68		Agustus	26.2	80	1013.2	25.1
69		September	26.7	80	1013.5	55.2
70		Oktober	27.6	79	1013.4	56.9
71		November	29.2	75	1010.8	72.3
72		Desember	28.6	77	1011.0	164.2
73	2010	Januari	27.5	82	1010.5	305.4
74		Februari	28.0	82	1011.5	112.3
75		Maret	28.8	77	1011.2	163.3
76		April	28.1	81	1010.7	181.5
77		Mei	28.1	83	1009.8	287.9
78		Juni	27.2	83	1012.1	154.0
79		Juli	26.9	85	1012.1	98.3
80		Agustus	26.7	84	1012.5	151.3
81		September	27.6	82	1011.7	80.7
82		Oktober	27.8	81	1010.5	207.7
83		November	28.8	76	1010.1	33.7
84		Desember	27.5	82	1007.2	139.0
85	2011	Januari	26.9	84	1007.8	181.6
86		Februari	27.4	82	1008.3	104.3
87		Maret	27.0	83	1008.7	139.9
88		April	27.3	83	1010.0	143.7
89		Mei	27.3	83	1010.9	96.4
90		Juni	26.0	80	1012.5	24.3
91		Juli	25.7	81	1012.7	41.8
92		Agustus	25.7	79	1013.3	8.0
93		September	26.4	79	1013.6	4.0
94		Oktober	27.6	77	1012.1	40.8
95		November	28.5	79	1009.9	106.0
96		Desember	28.2	80	1008.6	195.1
97	2012	Januari	27.7	79	1008.5	217.1
98		Februari	28.3	78	1008.8	110.5
99		Maret	27.5	81	1008.6	94.7
100		April	28.2	79	1011.3	53.3

No.	Tahun	Bulan	Suhu	Kelembapan	Tekanan	Curah Hujan
101	2012	Mei	27.4	82	1011.3	87.1
102		Juni	26.3	81	1012.7	15.3
103		Juli	26.4	82	1011.4	73.0
104		Agustus	25.8	77	1014.3	10.7
105		September	26.8	76	1014.0	11.5
106		Oktober	27.5	75	1012.6	6.3
107		November	28.5	76	1011.3	112.8
108		Desember	28.2	80	1009.3	156.6
109	2013	Januari	27.3	84	1009.5	527.5
110		Februari	28.2	79	1009.3	100.2
111		Maret	27.9	80	1010.9	193.1
112		April	27.9	81	1010.3	228.8
113		Mei	27.7	82	1010.9	97.3
114		Juni	27.2	85	1009.9	122.8
115		Juli	26.3	81	1012.1	156.0
116		Agustus	26.2	78	1013.7	37.3
117		September	26.7	75	1013.9	6.9
118		Oktober	28.6	72	1013.6	0.8
119		November	28.1	79	1010.5	237.6
120		Desember	27.7	81	1009.5	160.3

LAMPIRAN 2

M-File Neural Network menggunakan MATLAB R2014a

```
function net = fit_net(Inputn,Targetn)
% Data Untuk Prakiraan Curah Hujan 1 Bulan Ke Depan
x1 = [27.6 27.1 27.1 28.2 27.3 26.2 25.8 25.8 26.3 27.9 28.8 28.1
28.8 28 27.9 27.6 27.4 27.2 26.5 25.8 26.9 27.7 28.4 26.8 26.9
27.2 27 27.6 27.2 25.8 25 25.1 25.7 27.5 28.9 28.8 27.8 27.5 26.7
27.9 27.7 26.6 25.6 25.5 26.4 28.1 28.6 28.3 27.7 26.9 27 27.9
27.3 26.5 25.6 26 27 28.4 28.2 27.2 27.3 27 27.8 28.6 27.6 27 26.3
26.2 26.7 27.6 29.2 28.6 27.5 28 28.8 28.1 28.1 27.2 26.9 26.7
27.6 27.8 28.8 27.5 26.9 27.4 27 27.3 27.3 26 25.7 25.7 26.4 27.6
```

```
28.5 28.2 27.7 28.3 27.5 28.2 27.4 26.3 26.4 25.8 26.8 27.5 28.5];
x2 = [81 83 83 79 81 76 79 79 80 74 75 77 75 76 79 79 77 80 76 78
76 78 73 84 83 80 82 79 80 81 82 79 77 74 74 76 76 80 84 81 80 83
79 80 75 75 75 77 78 83 81 78 78 80 79 83 77 79 80 81 80 82 78 77
81 78 79 80 80 79 75 77 82 82 77 81 83 83 85 84 82 81 76 82 84 82
83 83 83 80 81 79 79 77 79 80 79 78 81 79 82 81 82 77 76 75 76];
x3 = [1010.1 1009.3 1009.3 1010.4 1010 1012.4 1011.6 1013 1013.7
1013.2 1010.9 1009.6 1009.1 1010.1 1009.9 1011.4 1011.5 1010.9 1011.8
1012.2 1012.2 1012 1011.2 1008.7 1008.6 1008.9 1008.7 1008.9 1010.6
1011.8 1013.1 1013 1013 1012.8 1010.4 1008.8 1010.2 1010.2 1008.6
1010.3 1011.6 1010.3 1013.2 1013.4 1013.1 1012.1 1010.4 1008.1 1009.1
1008.1 1009.3 1009.8 1011.7 1012.5 1013.2 1012.9 1013.1 1012 1009.5
1008.9 1009.4 1008.1 1010.5 1010.7 1010.5 1012.4 1013.3 1013.2 1013.5
1013.4 1010.8 1011 1010.5 1011.5 1011.2 1010.7 1009.8 1012.1 1012.1
1012.5 1011.7 1010.5 1010.1 1007.2 1007.8 1008.3 1008.7 1010 1010.9
1012.5 1012.7 1013.3 1013.6 1012.1 1009.9 1008.6 1008.5 1008.8 1008.6
1011.3 1011.3 1012.7 1011.4 1014.3 1014 1012.6 1011.3];
Input = [x1;x2;x3];
Target = [352.8 305.7 255.9 209.5 4.4 3.5 32.2 49.6 0 44.4 114.5 69.6
174.4 171.5 128.7 18.1 42.5 45.9 93.9 1.5 81.9 134.4 328.8 157.7
235.8 284.1 68.2 146.6 79.2 61.2 4.6 1.5 52.7 6.9 149.3 193.8 250.2
317.4 177.7 25.3 114.6 17.2 70.1 116.8 12.9 60.3 103.5 144.9 278.4
259.4 34 32.9 11.7 17.2 8.7 26.2 82.1 97.8 255 291.9 278.2 57.1 187
107 28.6 60.3 25.1 55.2 56.9 72.3 164.2 305.4 112.3 163.3 181.5 287.9
154 98.3 151.3 80.7 207.7 33.7 139 181.6 104.3 139.9 143.7 96.4 24.3
41.8 8 4 40.8 106 195.1 217.1 110.5 94.7 53.3 87.1 15.3 73 10.7 11.5
```

```
6.3 112.8 156.6];
```

```
%%%%%%%%%% PREPROCESSING %%%%%%%%%%%
```

```
%          NORMALISASI
```

```
a = min(x1);
```

```
b = max(x1);
```

```
x1n = (x1-a)/(b-a);
```

```
c = min(x2);
```

```
d = max(x2);
```

```
x2n = (x2-c)/(d-c);
```

```
e = min(x3);
```

```
f = max(x3);
```

```
x3n = (x3-e)/(f-e);
```

```
Inputn = [x1n;x2n;x3n];
```

```
g = min(Target);
```

```
h = max(Target);
```

```
Targetn = (Target-g)/(h-g);
```

```
%          MEMBANGUN BACKPROPAGATION
```

```
net = newff(minmax(Inputn),[7 1],{'logsig' 'logsig'},'traingda');
```

```

%           Set Parameter
net.trainParam.epochs = 200;
net.trainParam.goal = 0.02;
net.trainParam.lr = 0.350;
net.trainParam.show = 100;

%           Melakukan Pelatihan
net = train(net,Inputn,Targetn);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% APPLY NETWORK %%%%%%%%%%%%%%
%Data Input dan Target untuk Pengujian
xt1 = [28.2 27.3 28.2 27.9 27.9 27.7 27.2 26.3 26.2 26.7 28.6 28.1];
xt2 = [80 84 79 80 81 82 85 81 78 75 72 79];
xt3 = [1009.3 1009.3 1010.9 1010.3 1010.9 1009.9 1012.1 1013.7
1013.9 1013.6 1010.5 1009.5];
Inputs = [xt1;xt2;xt3];
Targets = [527.5 100.2 193.1 228.8 97.3 122.8 156 37.3 6.9 0.8 237.6
160.3];

%           NORMALISASI
xt1n = (xt1-a)/(b-a);
xt2n = (xt2-c)/(d-c);
xt3n = (xt3-e)/(f-e);
I_n = [xt1n;xt2n;xt3n];

```

```
net.IW{1,1};
Bobot_Input_Hidden = net.IW{1,1}

net.LW{2,1};
Bobot_Hidden_Output = net.LW{2,1}

net.b{1,1};
Bias_Hidden = net.b{1,1}

net.b{2,1};
Bias_Output = net.b{2,1}

Targets_n = (Targets-g)/(h-g)
Output_n = sim(net,I_n)

Prediksi_1_bulan_ke_depan = Output_n*(h-g)+g

n=12;
selisih2 = ((Targets_n-Output_n).^2)/2;
E_pengujian = (1/n)*(sum(selisih2))
```


SURAT PERNYATAAN KEASLIAN SKRIPSI

Dengan ini saya yang bertanda tangan di bawah ini, mahasiswa Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta:

Nama : Sifa Afnada Nailufar
No. Registrasi : 3125102326
Jurusan : Matematika
Program Studi : Matematika

Menyatakan bahwa skripsi ini yang saya buat dengan judul "**Model Prakiraan Curah Hujan Di Kabupaten Banyuwangi Menggunakan Metode Jaringan Syaraf Tiruan Dengan *Back-Propagation***" adalah :

1. Dibuat dan diselesaikan oleh saya sendiri.
2. Bukan merupakan duplikat skripsi yang pernah dibuat oleh orang lain atau jiplakan karya tulis orang lain.

Pernyataan ini dibuat dengan sesungguhnya dan saya bersedia menanggung segala akibat yang timbul jika pernyataan saya tidak benar.

Jakarta, Desember 2014

Yang membuat pernyataan

Sifa Afnada Nailufar

DAFTAR RIWAYAT HIDUP



SIFA AFNADA NAILUFAR. Lahir di Jakarta, 2 Juni 1993. Anak keenam dari pasangan Bapak Muttaqin dan Ibu Jauharotuz Zahro'. Saat ini bertempat tinggal di Kuningan Barat No.23A RT006/RW02, Mampang Prapatan, Jakarta Selatan.

No. Ponsel : 0898 8112 202 / 0858 9192 2074

Email : sifa_dafar@yahoo.com

Riwayat Pendidikan : Penulis mengawali pendidikan di TK Mamiri selama 1 tahun dan kemudian melanjutkan pendidikan di SD Negeri 03 Pagi selama 6 tahun. Setelah itu, pada tahun 2004, penulis melanjutkan ke SMP Negeri 43 Jakarta hingga tahun 2007. Pada tahun 2007 penulis melanjutkan ke SMA Negeri 55 Jakarta dan lulus tahun 2010. Kemudian pada tahun 2010 pula penulis mengikuti Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN) dan mendapat Jurusan Matematika, Universitas Negeri Jakarta (UNJ). Di awal tahun 2015, penulis telah memperoleh gelar Sarjana Sains untuk Jurusan Matematika, Program Studi Matematika, FMIPA, UNJ.

Riwayat Organisasi : Pada saat SMA, penulis aktif dalam organisasi sekolah yaitu Karya Ilmiah Remaja sebagai anggota di tahun pertama dan di tahun kedua sebagai sekretaris. Selama di bangku perkuliahan, penulis aktif di berbagai organisasi kemahasiswaan. Tahun pertama mendapat amanah sebagai staff Departemen Akademik BEMJ Matematika. Di dalam organisasi, penulis sering mengikuti berbagai macam kepanitiaan, seperti tim Lomba pada Pelangi Matematika 19, serta kepanitiaan kegiatan BEMJ Matematika yang lainnya.