

# **SKRIPSI**

**PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL  
*BIO-INSPIRED* DENGAN MENGGUNAKAN METODE  
*ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC  
EVOLUTIONARY ALGORITHMS* DI GARDU INDUK  
SENGKALING MALANG**



**Disusun Oleh :  
ZAINUL EFFENDI  
01.12.108**

**JURUSAN TEKNIK ELEKTRO S-1  
KONSENTRASI TEKNIK ENERGI LISTRIK  
FAKULTAS TEKNOLOGI INDUSTRI  
INSTITUT TEKNOLOGI NASIONAL MALANG**

**SEPTEMBER 2007**

---

**LEMBAR PERSETUJUAN**

**PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL  
BIO-INSPIRED DENGAN MENGGUNAKAN METODE  
ARTIFICIAL NEURAL NETWORKS DAN GENETIC  
EVOLUTIONARY ALGORITHMS DI GARDU INDUK  
SENGKALING MALANG**

**SKRIPSI**

*Disusun dan Diajukan Untuk Melengkapi dan Memenuhi Syarat-Syarat  
Guna Mencapai Gelar Sarjana Teknik*

**Disusun Oleh :  
ZAINUL EFFENDI  
NIM 01.12.108**

*Distujui :*



**Mengetahui  
Ketua Jurusan Teknik Elektro**

**Ir. F. Yudi Lampraptono, MT**  
NIP. P. 1039500274

**Disetujui  
Dosen Pembimbing**

**Ir. H. Choirul Saleh, MT**  
NIP. P. 1010880190

**KONSENTRASI TEKNIK ENERGI LISTRIK  
JURUSAN TEKNIK ELEKTRO S-1  
FAKULTAS TEKNOLOGI INDUSTRI  
INSTITUT TEKNOLOGI NASIONAL MALANG**

## ABSTRAKSI

### PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL *BIO-INSPIRED* MENGUNAKAN METODE *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORITHMS* DI GARDU INDUK SENGKALING MALANG

( Zainul Effendi , 01.12.108, Teknik Elektro Energi Listrik S – 1, ITN 2007 )  
( Dosen Pembimbing : Ir. H Choirul Saleh, MT )

**Kata Kunci** : *Sistem Distribusi, Artificial Neural Networks, Genetic Evolutionary Algorithms, Perkiraan Beban Jangka Pendek*

Kebutuhan akan tenaga listrik sangat penting sekali bagi kehidupan, oleh karena itu bagaimana cara mengoprasikan tenaga listrik yang selalu dapat memenuhi permintaan daya pada setiap saat dan dengan harga yang murah, dan apabila daya yang dibandingkan atau dikirimkan tidak memenuhi kebutuhan para konsumen maka akan terjadi kerugian baik dari pihak PLN ataupun pihak konsumen, oleh karena itu perlu adanya keseimbangan antara pembangkitan dengan permintaan daya, karena itu perkiraan beban baik jangka pendek, menengah, panjang sangat penting didalam perencanaan dan pengoprasian system daya agar bisa lebih baik.

Dalam skripsi yang saya ajukan ini merupakan salah satu solusi dalam perkiraan beban jangka pendek yang menggunakan metode *gabungan antara Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* yang digunakan untuk memperkirakan beban jangka pendek dengan tingkat kesalahan perkiraan yang kecil sehingga dapat diketahui berapa kebutuhan beban dimasa datang.

Dengan menggunakan data jaringan pada saluran distribusi di Gardu Induk Sengkaling Malang, di peroleh hasil perkiraan beban selama satu minggu dengan MAPE minimum sebesar 0,01% MAPE maksimum sebesar 9,69% dan MAPE rata-rata sebesar 0,053%

## KATA PENGANTAR

Dengan memanjatkan puji syukur kehadirat Allah SWT, atas limpahan Rahmat dan Hidayah-Nya, sehingga penyusun dapat menyelesaikan skripsi ini dengan judul :

**“ PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL *BIO-INSPIRED*  
MENGUNAKAN METODE *ARTIFICIAL NEURAL NETWORKS* DAN  
*GENETIC EVOLUTIONARY ALGORITHM* DI GARDU INDUK SENGKALING  
MALANG”**

Skripsi ini disusun sebagai salah satu persyaratan dalam menyelesaikan studi program strata satu (S-1) jurusan Teknik Elektro/Program Studi Teknik Energi Listrik, Fakultas Teknologi Industri, Institut Teknologi Nasional Malang

Sebelum dan selama penyusunan skripsi ini, penyusun telah banyak mendapatkan bantuan dan bimbingan dari berbagai pihak. Untuk itu pada kesempatan ini penyusun menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Bapak Ir. F. Yudi Limpraptono, MT, selaku Ketua Jurusan Teknik Elektro S-1 Fakultas Teknologi Industri Institut Teknologi Nasional Malang.
2. Bapak Ir.H, Choirul Saleh MT, selaku Dosen pembimbing dalam penyusunan skripsi ini.
3. Bapak dan Ibu Dosen Jurusan Teknik Elektro Energi Listrik.
4. Bapak dan Ibuku tercinta, yang sangat berarti dalam kehidupan penyusun, dimana do'a serta restu dan keridhaannya senantiasa penyusun harapkan.

## DAFTAR ISI

<b>LEMBAR PERSETUJUAN</b> .....	i
<b>ABSTRAKSI</b> .....	ii
<b>KATA PENGANTAR</b> .....	iii
<b>DAFTAR ISI</b> .....	v
<b>DAFTAR GAMBAR</b> .....	ix
<b>DAFTAR TABEL</b> .....	xi
<b>DAFTAR GRAFIK</b> .....	xii

### **BAB I PENDAHULUAN**

1.1. Latar Belakang .....	1
1.2. Perumusan Masalah .....	3
1.3. Tujuan Penelitian .....	3
1.4. Batasan Masalah .....	4
1.5. Metode Pembahasan .....	4
1.6. Sistematika Penulisan .....	5
1.7. Kontribusi .....	6

### **BAB II PERKIRAAN BEBAN LISTRIK**

2.1. Pendahuluan .....	7
2.2. Distribusi Sistem Tenaga Listrik .....	8
2.3. Sistem Distribusi Radial .....	9
2.4. Kurva Beban Listrik .....	10

3.7.1.	Penurunan Algoritma <i>Backpropagation</i> .....	37
3.8.	Inisialisasi Bobot Awal Secara Random .....	38
3.9.	Perhitungan Bobot Dengan <i>Backpropagation</i> .....	38
3.9.1	Algoritma Pembelajaran <i>Backpropagation</i> .....	39
3.10.	Peramalan Beban Jangka Pendek Dengan Mengetahui Model Dari Bio - Inspirasi.....	44
3.11.	Teori <i>Genetic Evolutionary Algorytms</i> .....	46

**BAB IV ANALISIS PRAKIRAAN BEBAN JANGKA PENDEK DENGAN  
MODEL *BIO – INSPIRED* DENGAN MENGGUNAKAN METODE  
*ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC  
EVOLUTIONARY ALGORythMS***

4.1.	Data Beban .....	47
4.2.	Program Komputer Metode <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorytms</i> .....	48
4.3.	Algoritma Program <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorytms</i> .....	49
4.4.	Penentuan Arsitektur Jaringan.....	52
4.4.1.	Diagram Alir Pemrosesan Bobot Input Menjadi Output Pada <i>Backpropagation</i> .....	54
4.4.2.	Diagram Alir Perkiraan Beban Listrik Dengan <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorytms</i> .....	56
4.5.	Prosedur Pelaksanaan Program Hasil Perkiraan .....	57

4.6.	Analisa Hasil Training.....	61
4.7.	Hasil Perkiraan Beban Listrik .....	62
4.8.	Analisa Hasil Perkiraan.....	70

## **BAB V KESIMPULAN DAN SARAN**

5.1.	Kesimpulan.....	71
5.2.	Saran.....	72

## **DAFTAR PUSTAKA**

## **LAMPIRAN**

## DAFTAR GAMBAR

Gambar 2-1	Jaringan Distribusi Beban .....	8
Gambar 2-2	Bagan jaringan tegangan menengah sistem radial .....	9
Gambar 2-3	Kurva beban harian .....	10
Gambar 2-4	Kurva karakteristik beban harian pada Gardu Induk.....	11
Gambar 2-5	Kurva perkiraan beban dan produksi jangka panjang .....	12
Gambar 2-6	Prinsip dasar perkiraan dengan dengan metode kecenderungan....	13
Gambar 2-7	Kurva pertumbuhan beban keseluruhan proses.....	14
Gambar 2-8	Kurva pertumbuhan beban komponen-komponennya .....	14
Gambar 2-9	Kurva Regresi .....	15
Gambar 2-10	Metode Koefisien Beban.....	17
Gambar 2-11	Metode Pendekatan Linier.....	18
Gambar 3-1	Susunan syaraf manusia .....	22
Gambar 3-2	Struktur neuron jaringan syaraf.....	24
Gambar 3-3	Jaringan syaraf dengan 3 lapisan.....	25
Gambar 3-4	Jaringan Syaraf Dengan Lapisan Tunggal .....	26
Gambar 3-5	Jaringan syaraf dengan banyak lapisan .....	27
Gambar 3-6	Fungsi aktivasi: Undak Biner (hard limid) .....	28
Gambar 3-7	Fungsi aktivasi: Undak biner (threshold).....	28
Gambar 3-8	Fungsi aktivasi:Bipolar (symetrik hard limid) .....	29
Gambar 3-9	Fungsi aktivasi: Bipolar (threshold).....	29
Gambar 3-10	Fungsi aktivasi:Linear (identitas).....	30
Gambar 3-11	Fungsi aktivasi: saturating Linear.....	30



Gambar 3-12	Fungsi aktivasi: symmetric saturating linear.....	31
Gambar 3-13	Fungsi Aktivasi: Sigmoid Biner.....	32
Gambar 3-14	Fungsi Aktifasi: Sigmoid Bipolar .....	32
Gambar 3-15	<i>Feedforward Neural Networks</i> .....	46
Gambar 4-1	Diagram Single Line G.I Sengkaling Malang.....	48
Gambar 4-2	Program <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorithms</i> .....	52
Gambar 4-3	Arsektektur Jaringan untuk perkiraan beban.....	52
Gambar 4-4	Diagram Alir <i>backpropagation</i> .....	54
Gambar 4-5	Diagram Alir Perkiraan Beban Listrik <i>Dengan Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorithms</i> .....	56
Gambar 4-6	Menu Utama Program .....	58
Gambar 4-7	Program <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorithms</i> .....	59
Gambar 4-8	Running Program <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorithms</i> .....	59

## DAFTAR TABEL

Tabel 4-1	Data inputan <i>Artificial Neural Networks</i> dan <i>Genetic Evolutionary Algorityms</i> .....	57
Tabel 4-2	Perbandingan Hasil prakiraan beban Rabu 1 Desember 2006 .....	63
Tabel 4-3	Perbandingan Hasil prakiraan beban Kamis 2 Desember 2006 .....	64
Tabel 4-4	Perbandingan Hasil prakiraan beban Jumat 3 Desember 2006 .....	65
Tabel 4-5	Perbandingan Hasil prakiraan beban Sabtu 4 Desember 2006.....	66
Tabel 4-6	Perbandingan Hasil prakiraan beban Minggu 5 Desember 2006 .....	67
Tabel 4-7	Perbandingan Hasil prakiraan beban Senin 6 Desember 2006.....	68
Tabel 4-8	Perbandingan Hasil prakiraan beban Selasa 7 Desember 2006 .....	69

## DAFTAR GRAFIK

Grafik 4-1	Proses Training Aplikasi Program <i>ANN – GEAs</i> Epochs 225.....	60
Grafik 4-2	Proses Training Aplikasi Program <i>ANN – GEAs</i> Epochs 466950.....	60
Grafik 4-3	Proses Training Aplikasi Program <i>ANN – GEAs</i> Epochs 636564.....	61
Grafik 4-4	Hasil Proses Training Dengan Perbandingan Antara Target Dan Output .....	61
Grafik 4-5	Perbandingan Hasil prakiraan beban Rabu 1 Desember 2006 .....	63
Grafik 4-6	Perbandingan Hasil prakiraan beban Kamis 2 Desember 2006 .....	64
Grafik 4-7	Perbandingan Hasil prakiraan beban Jumat 3 Desember 2006 .....	65
Grafik 4-8	Perbandingan Hasil prakiraan beban Sabtu 4 Desember 2006.....	66
Grafik 4-9	Perbandingan Hasil prakiraan beban Minggu 5 Desember 2006 .....	67
Grafik 4-10	Perbandingan Hasil prakiraan beban Senin 6 Desember 2006.....	68
Grafik 4-11	Perbandingan Hasil prakiraan beban Selasa 7 Desember 2006 .....	69

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Tenaga Listrik tidak dapat disimpan dalam skala besar karenanya tenaga ini harus disediakan pada saat dibutuhkan. Akibatnya timbul persoalan dalam menghadapi kebutuhan daya listrik yang tidak tetap dari waktu ke waktu, bagaimana mengoperasikan sistem tenaga listrik yang selalu dapat memenuhi permintaan daya pada setiap saat, dengan kualitas baik dan dengan harga yang murah. Apabila daya yang dikirim dari bus-bus pembangkit jauh lebih besar daripada permintaan daya pada bus-bus beban, maka akan timbul persoalan pemborosan energi pada perusahaan listrik, terutama untuk pembangkit thermal. Sedangkan apabila daya yang dibangkitkan dan dikirimkan lebih rendah atau tidak memenuhi kebutuhan konsumen maka akan terjadi pemadaman lokal pada bus-bus beban, yang akibatnya akan merugikan pihak konsumen. Oleh karena itu diperlukan penyesuaian antara pembangkit dengan permintaan daya.

Syarat mutlak yang harus dilakukan pertama untuk mencapai tujuan itu adalah pihak perusahaan listrik memperkirakan beban atau permintaan daya listrik dimasa depan. Karena itu prakiraan beban jangka pendek, menengah dan panjang merupakan tugas yang penting dalam perencanaan dan pengoperasian sistem daya. Prakiraan beban jangka pendek (*Short Term Load Forecasting / STLF*) yaitu beban setiap jam atau setiap hari digunakan untuk penjadwalan dan pengontrolan sistem daya atau alokasi pembangkit cadangan berputar, juga digunakan untuk masukan dalam studi aliran daya.

Untuk dapat melakukan prakiraan beban tersebut maka diperlukan metode-metode yang mampu memprediksi beban listrik untuk beberapa jam ke depan, atau beberapa hari ke depan bahkan beberapa minggu kemudian. Metode tersebut diantaranya : *regresi variabel multiple, analisis sensitiveitas cuaca, metode keadaan ruang, metode time series, metode sistem ahli artificial neural network dan lain-lain.*

Dari sekian banyak metode alternatif tersebut, ada salah satu metode alternatif yang mampu melakukan prakiraan ini. Metode tersebut adalah *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* karena metode ini mampu melakukan perkiraan beban jangka pendek dengan tingkat keakuratan yang tinggi dan dengan error yang sangat kecil, serta dapat mengaplikasikan neural network dengan koneksi umpan balik terbuka dalam waktu dan menjadi feedforward umum dengan penyebaran bobot, dimana setelah dilakukan proses pembelajaran menggunakan metode Backpropagation ANN dan GEAs akan didapat suatu output, dimana output tersebut akan menjadikan inputan lagi. Keuntungan utama dari model ini adalah dapat difungsikan atau digunakan untuk permasalahan optimasi dimana melepas seluruh kemungkinan solusi yang membutuhkan perhitungan besar didalam peramalan dengan tanpa mengurangi tingkat keakuratan didalam melakukan perhitungan.

## **1.2 Rumusan Masalah**

Mengacu pada latar belakang masalah, maksud dari proposal skripsi ini adalah bagaimana *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* dapat digunakan untuk memperkirakan beban jangka pendek dengan

error yang cukup kecil. Sehubungan dengan permasalahan diatas, maka penyusun menentukan judul skripsi sebagai berikut :

**“ PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL BIO –  
INSPIRED MENGGUNAKAN METODE *ARTIFICIAL NEURAL  
NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORYTHMS*  
DI GARDU INDUK SENGKALING MALANG”**

### **1.3 Tujuan Penelitian**

Tujuan yang ingin dicapai oleh penyusun adalah untuk menganalisis kerja dari *Artificial Neural Networks* dan *Genetic Evolutionary Elgorythms* sebagai metode alternatif dalam memperkirakan beban jangka pendek atau memperkirakan berapa jumlah beban yang diperlukan setiap hari atau memprakirakan beban beberapa jam kedepan sampai 168 jam kedepan (satu minggu), sehingga dapat diambil kesimpulan apakah metode tersebut baik dalam memperkirakan beban jangka pendek dengan tingkat keakurasian yang baik serta kesalahan (error) peramalan yang sekecil mungkin.

### **1.4 Batasan Masalah**

Dalam pembahasan masalah ini ada asumsi yang merupakan batasan masalah agar tidak meluas yaitu:

1. Metode yang digunakan adalah *Artificial Neural Networks* dan *Genetic Evolutionary Algorythms*.
2. Perhitungan perkiraan beban dilakukan dalam keadaan beban aktual.
3. Perhitungan dilakukan dengan program komputer ( Bahasa Pemrograman Matlab 6.5.1 ).

4. Sistem yang ditinjau Gardu Induk Sengkaling Malang.
5. Tidak membahas pendistribusian beban.
6. Untuk Jaringan Saraf Tiruan Pembelajaran yang dipakai pembelajaran Terawasi dengan metode pembelajaran BackPropagation dan Fungsi Aktivasi Sigmoid.

### 1.5 Metode Pembahasan

Metode pembahasan yang digunakan dalam skripsi ini adalah sebagai berikut:

1. Studi kepustakaan mengenai hal-hal yang berhubungan dengan pembahasan masalah.
2. Studi lapangan untuk mendapatkan data parameter beban pada Gardu Induk Sengkaling Malang.
3. Melakukan training program *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* pada beban yang diperoleh untuk mendapatkan bobot.
4. Melakukan perkiraan beban dengan *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* untuk mendapatkan bobot error yang kecil.
5. Membuat Evaluasi, sehingga dapat disimpulkan apakah metode yang diterapkan akurat untuk peramalan beban.

## 1.6 Sistematika Pembahasan

Untuk mendapatkan arah yang tepat mengenai hal-hal yang akan dibahas maka skripsi ini di susun sebagai berikut :

### BAB I : PENDAHULUAN

Meliputi Latar Belakang, Rumusan Masalah, Tujuan yang ingin dicapai, Batasan Masalah, Metodologi Penulisan dan Sistematika Pembahasan , Kontribusi.

### BAB II : PRAKIRAAN BEBAN LISTRIK

Berisi mengenai peranan Perkiraan Beban, klasifikasi perkiraan beban, factor-faktor yang mempengaruhi, Pemodelan perkiraan Beban, Metode Perkiraan Beban Listrik, Representasi Beban, Keakuratan.

### BAB III : TEORI *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORYTHMS* SERTA MENGETAHUI MODEL DARI BIO – INSPIRASI

Berisi tentang teori dasar Jaringan Syaraf Tiruan, Metode Backpropagation, dan Teori *Artificial Neural Networks* dan *Genetic Evolutionary Algorythms* serta cara kerja metode tersebut dalam memetakan input menjadi output yang sesuai.

### BAB IV : ANALISA PERAMALAN BEBAN JANGKA PENDEK DENGAN MENGGUNAKAN *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORYTHMS*



Berisi Pemilihan Variabel input dan output; Analisa metode dalam memperkirakan beban, dan petunjuk pengoperasian program.

## BAB V : PENUTUP

Meliputi kesimpulan dan saran.

### 1.7 Kontribusi

Dari hasil penelitian ini diharapkan akan memperoleh hasil ramalan beban yang tepat dengan kebutuhan beban yang akan datang. Hal ini akan memberikan manfaat dalam pembentukan pola karakteristik beban yang lebih baik, dan bisa digunakan sebagai laporan kondisi beban yang akan datang pada sistem yang lebih besar sehingga dapat digunakan sebagai acuan untuk melakukan penjadwalan beban dan untuk menentukan jadwal pembangkitan serta alokasi cadangan berputar, sehingga akan mencapai keandalan operasi sistem tenaga listrik yang lebih baik.

## BAB II PRAKIRAAN BEBAN LISTRIK

### 2.1. Pendahuluan

Selama bertahun-tahun perkiraan telah banyak diperbaiki dan sekarang mencapai tahap yang lebih tepat dan tidak menyimpang. Ini telah dipakai dalam bermacam-macam bidang seperti, perkiraan beban listrik, kecenderungan ekonomi, penyelidikan pasar dan lain-lain. Dalam sistem daya, perkiraan ini sangat dibutuhkan untuk memperkirakan dengan tepat beban listrik dan kebutuhan energi, karena dalam distribusi listrik dibutuhkan biaya yang cukup besar. Perkiraan dengan waktu yang nyata untuk jarak waktu yang pendek berubah dari beberapa menit sampai dengan beberapa jam telah sangat populer dalam penggunaan daya di negara-negara maju. Bila perkiraan energi terlalu kuno, maka akan terjadi bahwa kapasitas daya yang dibangkitkan oleh generator tidak cukup untuk memenuhi kebutuhan nyata, mengakibatkan keterbatasan dukungan satu daya yang akan merugikan kesejahteraan ekonomi negara. Namun bila perkiraan terlalu optimis, maka akan menjurus pada kelebihan kapasitas pembangkitan, akibatnya sebagian modal yang ditanam tidak kembali. Di suatu negara berkembang seperti Indonesia, dengan kedua kondisi diatas maka akan sangat tidak baik bagi perkembangan perekonomian, sehingga perkiraan beban harus menjadi salah satu prioritas yang tinggi.


Perkiraan beban dibidang Tenaga Listrik menghasilkan dua hasil utama, yaitu :

1. Perkiraan kebutuhan energi listrik (*demand*), yaitu energi yang dibutuhkan oleh pelanggan.

2. Perkiraan beban tenaga listrik (*load*), yaitu power yang perlu disediakan untuk memenuhi kebutuhan energi tersebut.

## 2.2. Distribusi Sistem Tenaga Listrik

Jaringan distribusi berada pada akhir sistem tenaga listrik, peranannya mendistribusikan tenaga listrik dari Gardu Induk (GI) ke konsumen melalui Gardu Distribusi. Jaringan yang keluar dari GI biasanya disebut jaringan distribusi. Setelah tenaga listrik disalurkan melalui jaringan distribusi primer maka kemudian tenaga listrik diturunkan tegangannya dalam gardu-gardu distribusi menjadi tegangan rendah, kemudian disalurkan melalui Jaringan Tegangan Rendah (JTR) untuk selanjutnya disalurkan ke rumah-rumah atau pelanggan (konsumen) PLN melalui sambungan rumah.




Gambar 2-1 Jaringan Distribusi Beban

Sumber: Ir.Djiteng Marsudi "Operasi Sistem Tenaga Listrik", hal 3

### 2.3. Sistem Jaringan Distribusi Radial

Bentuk jaringan ini merupakan bentuk dasar yang paling sederhana dan paling banyak digunakan. Sistem ini dikatakan radial karena kenyataan bahwa jaringan ini ditarik secara radial dari GI ke pusat-pusat beban konsumen yang dilayaninya. Sistem ini terdiri dari saluran utama dan saluran cabang seperti gambar berikut.



Gambar 2-2 Bagan jaringan tegangan menengah sistem radial


Sumber: Hasan Bisri, "Sistem Distribusi Tenaga Listrik", ISTN

Pelayanan tenaga listrik untuk suatu daerah beban tertentu dilaksanakan dengan memasang transformator pada sembarang titik pada jaringan yang sedekat mungkin dengan daerah beban yang dilayani. Untuk daerah beban yang menyimpang jauh dari saluran utama maupun saluran cabang, maka akan ditarik lagi saluran tambahan yang dicabangkan pada saluran tersebut. Kelemahan yang dimiliki oleh sistem radial adalah jatuh tegangan yang cukup besar dan bila terjadi

gangguan pada salah satu *feeder* maka semua pelanggan yang terhubung pada *feeder* tersebut akan terganggu.

#### 2.4. Kurva Beban Listrik


Beban tenaga listrik merupakan pemakaian tenaga listrik dari para pelanggan listrik. Pencatatan beban-beban pada suatu sistem distribusi perlu sekali diadakan untuk mengenali sebuah karakter dari beban itu sendiri dimana dari pencatatan harian hingga pada pencatatan beban tahunan. Dari hasil pencatatan beban itu kemudian diplotkan hingga membentuk kurva-kurva beban.



Gambar 2-3 Kurva beban harian

Sumber: Ir.Djitung Marsudi "Operasi Sistem Tenaga Listrik", hal 25

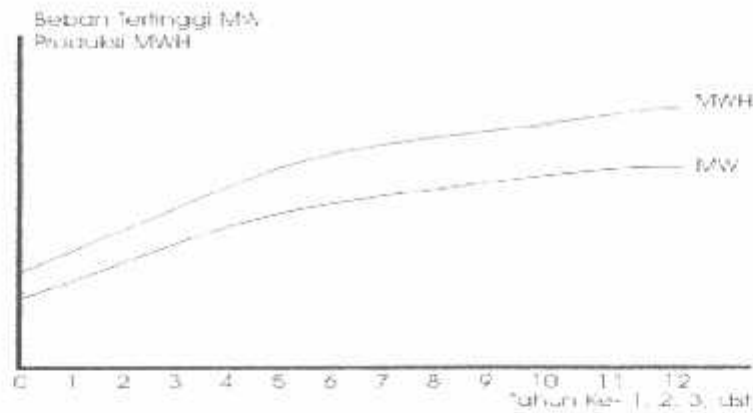
Dari gambar 2-3 diatas terlihat perbedaan karakter beban untuk keempat tipe beban harian. Beban pada hari-hari kerja dari senin-jumat pun sebenarnya juga memiliki perbedaan karakter.



Gambar 2-4 Kurva karakteristik beban harian pada Gardu Induk

Sumber: Ir.Djiteng Marsudi "Operasi Sistem Tenaga Listrik", hal 11

Dari kurva beban harian tersebut akan digunakan untuk perkiraan beban jangka panjang yang sangat berguna untuk pembangunan dan perkembangan suatu wilayah, baik industri, perkotaan maupun tenaga listrik itu sendiri.



Gambar 2-5 Kurva perkiraan beban dan produksi jangka panjang

Sumber: Ir.Djitung Marsudi "Operasi Sistem Tenaga Listrik", hal 26

## 2.5. Klasifikasi Prakiraan Beban Listrik

Menurut jangka waktu prakiraan beban diklasifikasikan sebagai berikut:

- Prakiraan beban jangka pendek  
Yaitu prakiraan beban yang memprakirakan beban beberapa jam kedepan sampai 168 jam kedepan (satu minggu)
- Prakiraan beban jangka menengah  
Yaitu prakiraan beban yang memprakirakan beban beberapa bulan sampai satu tahun
- Prakiraan beban jangka panjang  
Yaitu prakiraan beban yang memperkirakan beban diatas satu tahun

## 2.6. Metodologi Prakiraan


Metode prakiraan beban listrik dapat dibagi menjadi dua kelompok yaitu :

1. Berdasarkan Kecenderungan (*trend*)
2. Model Ekonometri

### 2.6.1. Metode Kecenderungan

Prakiraan beban dengan metode kecenderungan atau analisis regresi adalah mempelajari sifat-sifat sebuah proses di masa lampau dan membuatnya

sebagai suatu model matematis untuk masa mendatang, sehingga sifat atau kelakuan untuk masa mendatang dapat diekstrapolasikan.



Gambar 2-6 Prinsip dasar perkiraan dengan dengan metode kecenderungan

Sumber : AS Pabla, "Sistem Distribusi Daya Listrik", Erlangga, Jakarta 1986, Hal 6

Secara umum pendekatan dalam analisis kecenderungan ada dua cara, yaitu :

1. Pemasukan fungsi matematik kontinyu ke dalam data nyata untuk mendapatkan kesalahan keseluruhan terkecil, yang dikenal sebagai analisa regresi.
2. Pemasukan sebuah deret pada garis-garis kontinyu atau kurva-kurva ke dalam data.


Suatu kejadian yang berubah-ubah sebagai fungsi waktu misalnya beban suatu sistem daya dapat dipecah-pecah dalam 4 komponen utama, yaitu :

1. Kecenderungan dasar (*basic trend*) gerakan, berjangka panjang, lamban dan kecenderungan menuju satu arah menaik atau menurun.
2. Variasi musiman (*seasonal variation*), merupakan gerakan yang berulang secara teratur selam kurang lebih setahun (beban bulan, beban tahunan).
3. Variasi siklis (*syclic variation*), berlangsung selama lebih dari setahun dan tidak pernah variasi tersebut memperlihatkan pola tertentu mengenai pola gelombangnya.




- Perubahan-perubahan beban acak yang diamati dari perubahan beban-beban harian pada sistem tenaga, biasanya dalam seminggu atau pada waktu tertentu, misalnya hari libur, cuaca tertentu, dan sebagainya.

Pada gambar 2-7 diperlihatkan suatu model proses yang bervariasi kontinyu yang terdiri dari 3 komponen dasar seperti gambar 2-8



Gambar 2-7 Kurva pertumbuhan beban keseluruhan proses

Sumber : AS Pabla, "Sistem Distribusi Daya Listrik", Erlangga, Jakarta 1986, hal 16




Gambar 2-8 Kurva pertumbuhan beban komponen-komponennya

Sumber : AS Pabla, "Sistem Distribusi Daya Listrik", Erlangga, Jakarta 1986, hal 16

Dalam peramalan, model proses keseluruhannya dapat dipakai atau hanya beberapa titik-titik tertentu dari keseluruhan prosesnya. Sebagai contoh, misalnya dengan membuat perkiraan dari kurva beban yang komplis atau alternatif lainnya dengan hanya membuat perkiraan sistem beban puncak tahunannya saja,

hal ini proses modelnya dilakukan sebagai deret berkala (*time series*) seperti terlihat pada gambar 2-9



Gambar 2-9 Kurva Regresi

Sumber : AS Pabla, "Sistem Distribusi Daya Listrik", Erlangga, Jakarta 1986, hal 16

### 2.6.2. Metode Ekonometri

Pada umumnya model ini dikaitkan dengan sifat dari salah satu fungsi-fungsi ekonomi dalam bentuk fungsi-fungsi ekonomi lainnya. Model ekonometri sebenarnya sama dengan model statistic, karena semua variabelnya sudah tertentu dan secara matematis dapat diukur, seperti pada perencanaan, seringkali modelnya terdiri dari suatu persamaan, dalam hal ini modelnya disebut model regresi.

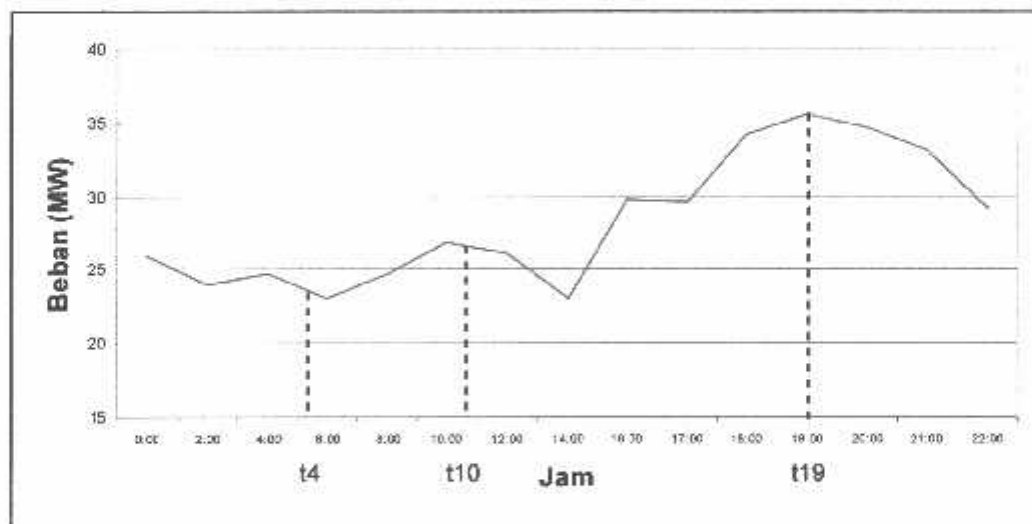
### 2.7. Faktor-Faktor Yang Mempengaruhi Beban

Pertumbuhan beban jangka panjang mempunyai korelasi yang kuat dengan aspek pengembangan komunitas dan pengembangan lahan. Faktor ekonomi seperti laju kenaikan pendapatan penduduk perkapita, data demografi, dan tata penggunaan lahan serta pengembangannya merupakan data-data input dalam proses prakiraan beban jangka panjang. Sedangkan output prakiraan beban tersebut dapat berupa kerapatan beban yang dapat dinyatakan dalam kVA

suhu udara tinggi maka pemakaian alat-alat penyejuk udara bertambah dan ini menambah pemakaian tenaga listrik. Hal ini menyebabkan tidak adanya rumus yang baku dalam memprakirakan beban. Beberapa metode yang dipakai untuk memprakirakan beban saat ini antara lain metode koefisien beban dan metode pendekatan linier.

### 2.8.1. Metode Koefisien Beban

Metode ini dipakai untuk memprakirakan beban harian dari suatu sistem tenaga listrik. Beban setiap jam diberi koefisien yang menggambarkan besarnya beban pada jam tersebut dalam perbandingannya terhadap beban puncak, misalnya  $k_8 = 0,8$  berarti beban pada jam 10:00 adalah sebesar 0,8 kali beban puncak yang terjadi pada jam 19:00 ( $k_{19} = 1$ ).



Gambar 2-10 Metode Koefisien Beban

Sumber : Ir.Djitung Marsudi "Operasi Sistem Tenaga Listrik", hal 30

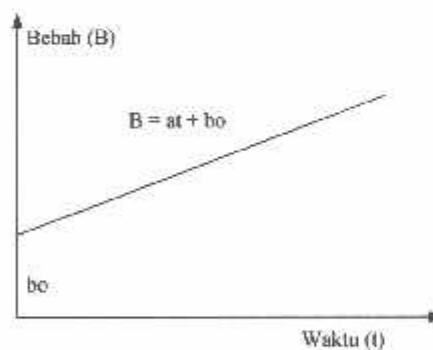
Koefisien-koefisien ini berbeda untuk hari senin sampai dengan minggu dan juga hari libur (bukan minggu). Beban puncak dapat diprakirakan dengan melihat beban puncak mingguan tahun-tahun yang lalu kemudian dengan

menggunakan koefisien-koefisien tersebut diatas bisa digunakan untuk memprakirakan grafik beban harian untuk satu minggu yang akan datang. Koefisien-koefisien ini perlu dikoreksi secara terus-menerus berdasarkan hasil pengamatan atas beban yang sesungguhnya terjadi.

Setelah didapat prakiraan grafik beban harian dengan metode koefisien masih perlu dilakukan koreksi-koreksi berdasarkan situasi terakhir mengenai prakiraan suhu dan kegiatan masyarakat. Jika koreksi-koreksi itu ternyata masih ada penyimpangan dalam operasi *real time*, maka adalah tugas operator sistem (*dispatcher*) untuk mengatasi penyimpangan ini.

$$k = \frac{VI(kW) \text{ pada jam tertentu}}{VI(kW) \text{ pada beban tertentu}} \dots\dots\dots (2.1)$$

**2.8.2. Metode Pendekatan Linier**



Gambar 2-11 Metode Pendekatan Linier

Sumber : Ir,Djiteng Marsudi "Operasi Sistem Tenaga Listrik", hal 31

Dengan menggunakan persamaan linier :

$$B = at + b_0 \dots\dots\dots (2.2)$$

dimana:

$B$  = beban pada saat  $t$

$a$  = suatu konstanta yang harus ditentukan

$b_0$  = beban pada saat  $t = t_0$

Konstanta  $a$  sesungguhnya tergantung pada waktu  $t$  dan besarnya  $b_0$ .

Cara ini hanya dapat dipakai untuk prakiraan beban beberapa puluh menit kedepan dan biasanya konstanta  $a$  juga tergantung kepada perkiraan cuaca.

### 2.9. Pemodelan Kurva Beban

Dalam praktek standar, operator sistem perlu menyesuaikan hasil prakiraan beban agar dapat memperhitungkan data beban yang terakhir. Hasil penyesuaian ini dapat berbeda drastis dengan hasil prakiraan beban yang sebenarnya. Dengan menggunakan pemodelan beban hari ini (*current day modeling*) kita dapat mengakomodasi kejadian ini. Selain itu mungkin juga operator sistem memerlukan prakiraan beban untuk 7 (tujuh) hari kedepan agar dapat dilakukan penjadwalan. Untuk itu disediakan fasilitas prakiraan mingguan.

Pada semua model-model yang dikembangkan perhatian khusus diberikan dalam mempresentasikan secara akurat efek dari kejadian khusus seperti hari libur.

- **Pemodelan hari ini**

Pemodelan untuk hari-hari biasa, yaitu hari Senin sampai Minggu yang bukan hari libur nasional diklasifikasikan berikut:

1. Pola beban hari Senin
2. Pola beban hari Selasa
3. Pola beban hari Rabu
4. Pola beban hari Kamis
5. Pola beban hari Jumat
6. Pola beban hari Sabtu
7. Pola beban hari Minggu

- **Pemodelan Mingguan**

Model ini menghasilkan beban sampai 168 jam ke depan. Untuk itu model dasar dikerjakan secara berulang-ulang untuk menghasilkan prakiraan beberapa hari. Jika data beban historis tidak ada, hasil prakiraan beban digunakan sebagai input.

#### **2.10. Representasi Beban**

Dalam sistem distribusi beban dipresentasikan menjadi 2 macam yaitu :

- **Beban Resistif**

adalah beban listrik yang terjadi dari tahanan ohm saja, yang mana beban ini hanya mengkonsumsi daya aktif saja.

Contoh : Lampu pijar

- **Beban Reaktif**

adalah beban listrik yang selain mengkonsumsi daya aktif, juga mengkonsumsi daya reaktif, yang sering terjadi adalah beban listrik yang terjadi dari induktansi (lilitan).

Contoh : Pemanas air, Strika listrik, Motor listrik

Daya terpakai (efektif) yang merupakan beban distribusi sistem tenaga listrik adalah Daya Aktif (Watt), didefinisikan seperti berikut :

$$P = V \times I \times \cos \varphi \dots\dots\dots (2.3)$$

### 2.11. Keakuratan Prediksi

Persentase mutlak kesalahan (*Mean Absolut Percentage Error*) digunakan untuk mempelajari performa *Artificial Neural Networks* dan *Genetic evolutionary algorithms*

$$MAPE = \left( \frac{1}{N} \right) \sum_{i=1}^N \frac{|beban\ perkiraan - beban\ aktual|}{beban\ aktual} \times 100\% \dots\dots\dots (2.4)$$

dimana :

$N$  = jumlah observasi

Presentase error dengan jangkauan 1 – 10 %, sudah sebanding dengan SLTF (*Short-Term Load Forccasting*) ANN.


**BAB III**  
**TEORI JARINGAN SARAF TIRUAN DAN *GENETIC EVOLUTIONARY***  
***ALGORYTHMS***  
**DAN MENGETAHUI MODEL DARI *BIO – INSPIRASI***

**3.1. Jaringan Syaraf Tiruan**

Jaringan syaraf tiruan merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah buatan disini digunakan karena jaringan syaraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran.

**3.2. Otak manusia**

Otak manusia berisi berjuta-juta sel syaraf yang bertugas untuk memproses informasi. Tiap-tiap sel bekerja seperti suatu prosesor sederhana. Masing-masing sel tersebut saling berinteraksi sehingga mendukung kemampuan kerja otak manusia.



Gambar 3-1 Susunan syaraf manusia

Sumber : Sri Kusumadewi "Artificial Intelligence", hal 207




Gambar 3-1 menunjukkan susunan syaraf pada manusia. Setiap sel syaraf

Setiap sel syaraf (*neuron*) akan memiliki satu inti sel, inti sel ini nanti yang akan bertugas untuk melakukan proses pemrosesan informasi. Informasi yang datang akan diterima oleh dendrit. Selain menerima informasi, dendrit juga menyertai axon sebagai keluaran dari suatu pemrosesan informasi. Informasi hasil olahan ini akan menjadi masukan bagi *neuron* lain yang mana antar dendrit kedua sel tersebut dipertemukan dengan *synapsis*. Informasi yang datang akan diterima oleh dendrit akan dijumlahkan dan dikirim melalui axon ke dendrit akhir yang bersentuhan dengan dendrit dari *neuron* lain. Informasi ini akan diterima oleh *neuron* lain jika memenuhi batasan tertentu, yang sering dikenal dengan nilai ambang (*threshold*). Pada kasus ini, *neuron* tersebut dikatakan teraktivasi. Hubungan antar *neuron* terjadi secara adaptif, artinya struktur hubungan tersebut terjadi secara dinamis. Otak manusia selalu memiliki kemampuan untuk belajar dengan melalui adaptasi.

### 3.3. Komponen Jaringan Syaraf Tiruan

Ada beberapa type jaringan syaraf, namun demikian, hampir semuanya memiliki komponen-komponen yang sama. Seperti halnya otak manusia, jaringan syaraf juga terdiri dari beberapa *neuron*, dan ada hubungan antara *neuron-neuron* tersebut. *Neuron-neuron* tersebut akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju ke *neuron-neuron* yang lain. Pada jaringan syaraf, hubungan ini dikenal dengan nama bobot. Informasi tersebut disimpan pada suatu nilai tertentu pada bobot tersebut. Gambar 3-2 menunjukkan struktur *neuron* pada jaringan syaraf.



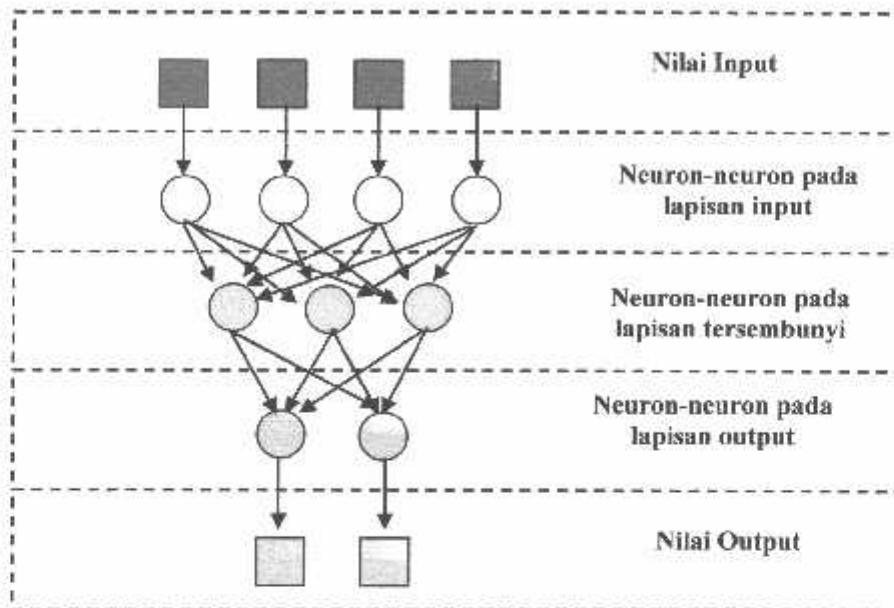
Gambar 3-2 Struktur neuron jaringan syaraf

Sumber : Sri Kusumadewi "Artificial Intelligence", hal 210

Jika dilihat *neuron* buatan ini sebenarnya mirip dengan sel *neuron* biologis. *Neuron-neuron* tersebut bekerja dengan cara yang sama pula dengan *neuron-neuron* biologis. Informasi ( disebut dengan : *input* ) akan dikirim ke *neuron* dengan bobot kedatangan tertentu. Input ini akan diproses oleh suatu fungsi perambatan yang akan menjumlahkan nilai-nilai semua bobot yang datang. Hasil penjumlahan ini kemudian akan dibandingkan dengan suatu nilai ambang tertentu (*threshold*) melalui **fungsi aktivasi** setiap *neuron*.

Pada jaringan syaraf, *neuron-neuron* akan dikumpulkan dalam lapisan-lapisan (*layer*) yang disebut dengan lapisan *neuron* (***neuron layer***). Biasanya *neuron-neuron* pada lapisan akan dihubungkan dengan lapisan-lapisan sebelum dan sesudahnya (kecuali lapisan input dan lapisan *output*). Informasi yang diberikan pada jaringan syaraf akan dirambatkan lapisan ke lapisan, mulai dari lapisan *input* sampai ke lapisan *output* melalui yang lainnya, yang sering dikenal dengan dengan nama lapisan tersembunyi (***hidden layer***). Tergantung pada algoritma pembelajarannya, bisa jadi informasi tersebut akan dirambatkan secara mundur pada jaringan. Gambar 3-3, menunjukkan jaringan syaraf dengan 3 lapisan. Gambar 3-3, bukanlah struktur umum jaringan syaraf. Beberapa jaringan

syaraf ada juga yang tidak memiliki lapisan tersembunyi, dan ada juga jaringan syaraf dimana *neuron-neuronnya* disusun dalam bentuk matriks.



Gambar 3-3 Jaringan syaraf dengan 3 lapisan

Sumber : Sri Kusumadewi "Artificial Intelligence", hal 211

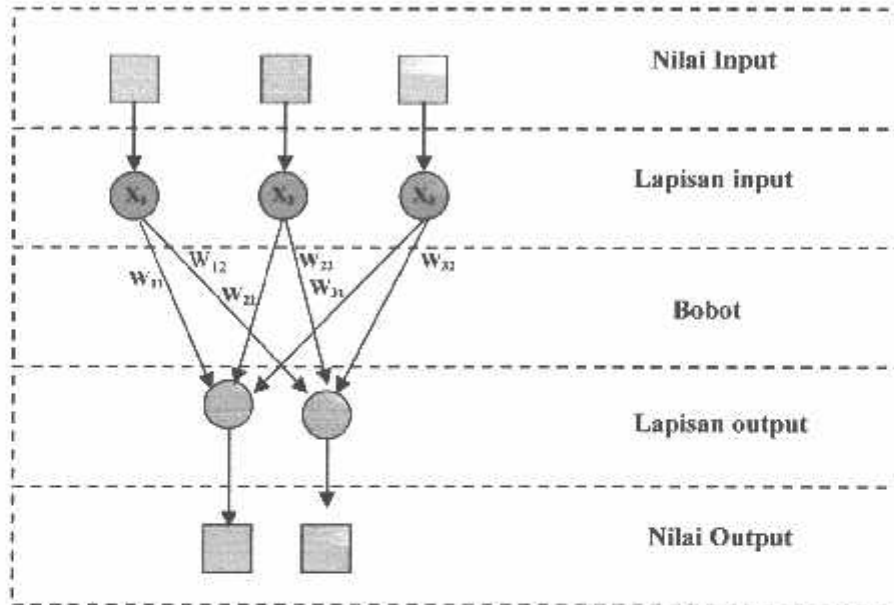
### 3.4. Arsitektur Jaringan

Seperti telah dijelaskan sebelumnya bahwa *neuron-neuron* dikelompokkan dalam lapisan-lapisan. Umumnya *neuron-neuron* yang terletak pada lapisan yang sama akan memiliki keadaan yang sama. Faktor terpenting dalam menentukan kelakuan suatu *neuron* adalah fungsi aktivasi dan pola bobotnya. Pada setiap lapisan yang sama, *neuron-neuron* akan memiliki fungsi aktivasi yang sama. Apabila *neuron-neuron* dalam suatu lapisan (misalkan lapisan tersembunyi) akan dihubungkan dengan *neuron-neuron* pada lapisan yang lain (misalkan lapisan *output*), maka setiap *neuron* pada lapisan tersebut (misalkan lapisan tersembunyi) juga harus dihubungkan dengan setiap lapisan lainnya (misalkan lapisan *output*).

Ada beberapa arsitektur jaringan syaraf, antara lain:

### 1. Jaringan dengan lapisan tunggal ( single layer net)

Jaringan dengan lapisan tunggal hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima input kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus menjadi lapisan tersembunyi.




Gambar 3-4 Jaringan Syaraf Dengan Lapisan Tunggal

Sumber : Sri Kusumadewi "Artificial Intelligence", hal 212

### 2. Jaringan dengan banyak lapisan (multilayer net)

Jaringan dengan banyak lapisan memiliki 1 atau lebih lapisan terletak diantara lapisan *input* dan lapisan *output* (memiliki 1 atau lebih lapisan tersembunyi), seperti terlihat pada gambar 3-5. Jumlah *hidden* unit tergantung pada kebutuhan. Sampai sekarang belum ada rumusan atau ketetapan mengenai jumlah pemakaian *hidden* unit. Terdapat dua buah layer dengan bobot  $v$  dan  $w$ . Umumnya, ada lapisan bobot-bobot yang terletak diantara 2 lapisan (*layer*) yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit daripada jaringan dengan lapisan tunggal, tentu saja dengan pembelajaran

yang lebih rumit. Namun demikian, pada banyak kasus, pembelajaran pada jaringan dengan banyak lapisan ini lebih sukses dalam menyelesaikan masalah.



Gambar 3-5 Jaringan syaraf dengan banyak lapisan

Sumber : Sri Kusumadewi "Artificial Intelligence", hal 213

### 3.5. Fungsi Aktifasi


Fungsi aktifasi adalah fungsi yang mengolah data input menjadi data output. Fungsi ini biasanya berupa fungsi pemampat (*Squashing Function*). Ada beberapa fungsi aktivasi yang sering digunakan dalam jaringan syaraf tiruan, antara lain:

#### A. Fungsi undak biner (Hard Limit)

Jaringan dengan lapisan tunggal sering menggunakan fungsi undak (step function) untuk mengkonversikan input dari suatu variable yang bernilai kontinue ke suatu output biner (0 atau 1)

gambar 3.6. Fungsi undak biner (hard limit) dirumuskan sebagai :

$$y = \begin{cases} 0, & \text{jika } x \leq 0 \\ 1, & \text{jika } x > 0 \end{cases}$$




Gambar 3.6  
Fungsi aktivasi: Undak Biner (hard limit)

#### B. Fungsi Undak Biner (threshold)

Fungsi undak biner dengan menggunakan nilai ambang sering juga disebut dengan nama fungsi nilai ambang (threshold) atau fungsi heuviside (Gambar 3.7).

Fungsi Undak Biner (dengan nilai ambang  $\theta$ ) dirumuskan sebagai:

$$y = \begin{cases} 0, & \text{jika } x < \theta \\ 1, & \text{jika } x \geq \theta \end{cases}$$




Gambar 3.7  
Fungsi aktivasi: undak biner (threshold)

C. Fungsi Bipolar sebenarnya hampir sama dengan fungsi undak biner, hanya noutput yang dihasilkan berupa 1,0 atau (Gambar 3.8).

Fungsi Symetrik Hard Limit dirumuskan sebagai:

$$y = \begin{cases} 0, & \text{jika } x > \theta \\ 1, & \text{jika } x = \theta \\ -1, & \text{jika } x < \theta \end{cases}$$




Gambar 3.8  
Fungsi aktivasi: Bipolar (symetrik hard limit)

#### D. Fungsi Bipolar (dengan threshold)

Fungsi bipolar sebenarnya hampir sama dengan fungsi undak biner dengan threshold, hanya saja output yang dihasilkan berupa 1, 0 atau -1 (Gambar 3.9)

Fungsi bipolar (dengan nilai ambang 0) dirumuskan sebagai :


$$y = \begin{cases} 1, & \text{jika } x \geq \theta \\ -1, & \text{jika } x < \theta \end{cases}$$



Gambar 3.9  
Fungsi aktivasi: bipolar (threshold)

E. Fungsi linear (identitas)

Fungsi linear memiliki nilai output yang sama dengan nilai inputnya (Gambar 3.10). Fungsi linear dirumuskan sebagai:




Gambar 3.10  
Fungsi aktivasi: Linear (identitas)

F. Fungsi Saturating linear

Fungsi ini akan bernilai 0 jika inputnya kurang dari -0.5, dan akan bernilai 1 jika inputnya lebih dari 0.5. Sedangkan jika nilai input terletak antara -0.5 dan 0.5 maka outputnya akan bernilai sama dengan nilai input ditambah 0.5 (Gambar 3.11).

Fungsi saturating linear dirumuskan sebagai berikut :

$$y = \begin{cases} 1; & \text{jika } x > 0.5 \\ x + 0.5; & \text{jika } -0.5 \leq x \leq 0.5 \\ -1; & \text{jika } x < -0.5 \end{cases}$$



Gambar 3.11  
Fungsi aktivasi: saturating Linear




G. Fungsi symmetric saturating linear

Fungsi ini akan bernilai -1 jika inputnya kurang dari -1, dan akan bernilai 1 jika inputnya lebih dari 1. Sedangkan jika nilai input terletak antara -1 dan 1, maka outputnya akan bernilai sama dengan nilai inputnya (Gambar 3.12).

Fungsi symmetric saturating linear dirumuskan sebagai:

$$y = \begin{cases} 1; & \text{jika } x \geq 1 \\ x; & \text{jika } -1 \leq x \leq 1 \\ -1; & \text{jika } x \leq -1 \end{cases}$$




Gambar 3.12  
Fungsi aktivasi: symmetric saturating linear

H. Fungsi sigmoid biner.

Fungsi ini akan digunakan untuk jaringan syaraf yang akan dilatih dengan menggunakan metode backpropagation. Fungsi sigmoid biner memiliki nilai pada range 0 sampai 1. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai output yang terletak pada interval 0 sampai 1. Namun fungsi ini bisa juga digunakan oleh jaringan syaraf yang nilai outputnya 0 sampai 1 (Gambar 3.13). Fungsi sigmoid biner dirumuskan

sebagai:  $Y = f(x) = \frac{1}{1 + e^{-\alpha x}}$ , dengan  $f'(x) = \sigma f(x)[1-f(x)]$




Gambar 3.13  
Fungsi Aktivasi: Sigmoid Biner

### 1. Fungsi Sigmoid Bipolar

Fungsi Sigmoid Bipolar hampir sama dengan fungsi Sigmoid Biner, hanya saja output dari fungsi ini memiliki range antara 1 sampai -1 (Gambar 3.14).

Fungsi sigmoid bipolar dirumuskan sebagai :



Gambar 3.14  
Fungsi Aktifasi: Sigmoid Bipolar

### 3.6. Proses Pembelajaran

Pada otak manusia, informasi yang dilewatkan dari satu *neuron* yang lainnya berbentuk rangsangan listrik melalui dendrit. Jika rangsangan tersebut diterima oleh suatu *neuron*, maka *neuron* tersebut akan membangkitkan *output* kesemua *neuron* yang berhubungan dengannya sampai informasi tersebut sampai ketujuannya yaitu terjadinya suatu reaksi. Jika rangsangan yang diterima terlalu halus, maka *output* yang dibangkitkan oleh *neuron* tersebut tidak akan direspon. Tentu saja sangatlah sulit untuk memahami bagaimana otak manusia bisa belajar. Selama proses pembelajaran, terjadi perubahan yang cukup berarti pada bobot-bobot yang menghubungkan antar *neuron*. Apabila ada rangsangan yang sama dengan rangsangan yang telah diterima oleh *neuron*, maka *neuron* akan memberikan reaksi dengan cepat. Namun, apabila kelak ada rangsangan yang berbeda dengan apa yang telah diterima oleh *neuron*, maka *neuron* akan segera beradaptasi untuk memberikan reaksi yang sesuai.

Jaringan syaraf akan mencoba untuk mensimulasikan kemampuan otak manusia untuk belajar. Jaringan syaraf tiruan juga tersusun atas *neuron-neuron* dan dendrit. Tidak seperti model biologis, jaringan syaraf memiliki struktur yang tidak dapat diubah, dibangun oleh sejumlah *neuron*, dan memiliki nilai tertentu yang menunjukkan seberapa besar koneksi antara *neuron* ( yang dikenal dengan nama bobot). Perubahan yang terjadi selama proses pembelajaran adalah perubahan nilai bobot. Nilai bobot akan bertambah, jika informasi yang diberikan oleh *neuron* yang bersangkutan tersampaikan, sebaliknya jika informasi tidak disampaikan oleh suatu *neuron* ke *neuron* yang lain, maka nilai bobot yang menghubungkan keduanya akan dikurangi. Pada saat pembelajaran dilakukan

pada input yang berbeda, maka nilai bobot akan diubah secara dinamis hingga mencapai suatu nilai yang cukup seimbang. Apabila nilai ini telah tercapai mengindikasikan bahwa tiap-tiap input telah berhubungan dengan *output* yang diharapkan.

### 3.6.1. Pembelajaran terawasi (*supervised learning*)

Metode pembelajaran pada jaringan syaraf disebut terawasi jika *output* yang diharapkan telah diketahui sebelumnya. Dalam proses belajar yang terawasi, seolah-olah ada "guru" yang mengajari jaringan. Contoh: andaikan kita memiliki jaringan syaraf yang akan digunakan untuk mengenali pasangan pola, misalkan pada operasi AND:

Input		Target
0	0	0
0	1	0
1	0	0
1	1	1

Pada proses pembelajaran (*training*), satu pola *input* akan diberikan ke satu *neuron* lagi. pada lapisan *input*. Pola ini akan dirambatkan disepanjang jaringan syaraf hingga sampai ke *neuron* pada lapisan *output*. Lapisan *output* ini akan membangkitkan pola *output* yang nantinya akan dicocokkan dengan pola *output* tagetnya.

Apabila terjadi perbedaan antara pola *output* hasil pembelajaran dengan pola target, maka disini akan muncul *error*. Apabila nilai *error* ini masih cukup besar, mengindikasikan bahwa masih perlu dilakukan banyak pembelajaran

Dalam proses belajar yang terawasi , seolah-olah ada "guru" yang mengajari jaringan. Cara pelatihan jaringan tersebut adalah dengan memberikan data-data yang disebut training data terdiri atas pasangan *input-output* yang diharapkan. Data-data itu biasanya, didapat dari pengalaman atau pengetahuan seseorang dalam penyelesaian persoalan. Setelah jaringan dilatih, akan mengingat suatu pola. Jika jaringan diberi *input* baru, jaringan dapat mengeluarkan *output* seperti yang diharapkan (*desired* atau *target output*) berdasarkan pola yang sudah ada.

Ada banyak metode yang menggunakan prinsip pembelajaran terawasi ini, antara lain:

1. Hebb rule
2. Perceptron
3. Delta Rule
4. Heteroassociative Memory
5. Counter Propagation
6. Backpropagation

Dari keenam metode tersebut, metode yang paling sering digunakan adalah *Backpropagation*. Ini dikarenakan backpropagation selain cukup simpel, metode ini juga telah terbukti mampu menyelesaikan masalah yang rumit dengan sukses. Oleh karena dalam skripsi ini juga menggunakan metode pembelajaran *backpropagation*.

### 3.6.2. Pembelajaran Tak Terawasi

Pada metode pembelajaran tak terawasi tidak memerlukan target *output*. Pada metode ini, tidak dapat ditentukan hasil yang seperti apakah yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu range tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah pengelompokan unit-unit yang hampir sama dalam suatu area tertentu. Pembelajaran ini biasanya sangat cocok untuk pengelompokan (klasifikasi) pola. Metode yang dipakai dalam proses belajar tak terawasi ini antara lain *Kohonen self-organizing Maps*.

Perlu diketahui, bahwa biasanya dalam pelatihan jaringan, selain ada data untuk *training (training set)*, juga ada data untuk tes (*test set*). Training data, selain digunakan untuk pelatihan, juga digunakan untuk memantau besarnya *error* yang terjadi antara *output* yang dihasilkan jaringan dengan *output* yang diharapkan. *Training* data akan mempengaruhi proses pelatihan. Jadi, pada training data set, baik data *input* maupun *output*, semuanya digunakan untuk pelatihan (*training*). Sedangkan test set dipakai dalam perhitungan (prakiraan) untuk mengetahui *output* yang dihasilkan jaringan karena adanya data *input*. Dalam *test* tersebut, dapat diketahui seberapa banyak jaringan telah belajar (iterasi atau epoch) dari pelatihan dan apakah jaringan telah mampu untuk menghasilkan *output* yang benar dengan bobot yang sudah ada. Data *output* pada *test* set hanya digunakan untuk menentukan besarnya *error* dengan cara membandingkan *output* jaringan dengan *output* yang diharapkan (tidak mempengaruhi proses pelatihan). Tidak ada aturan khusus tentang banyaknya *training data* dan *test data* tersebut. Jadi *training data* dan *test data* diambil secukupnya sesuai dengan kebutuhan

### 3.7. *Backpropagation*

*Backpropagation* merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyinya. Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*feed forward*) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, *neuron-neuron* diaktifkan dengan menggunakan fungsi aktivasi sigmoid.

#### 3.7.1. Penurunan Algoritma *Backpropagation*

Algoritma *backpropagation* terdiri atas tahapan propagasi maju dan tahapan propagasi balik. Tahapan propagasi maju dimulai dengan memberikan suatu pola (sinyal) masukan pada lapisan *input* pada jaringan. Pada lapisan *input*, pola masukan hanya dilewatkan untuk kemudian dikalikan dengan pebobot yang menghubungkan dengan lapisan *hidden*. Jadi lapisan *input* merupakan lapisan pasif karena tidak mengolah pola masukan. Dalam tiap lapisan yang berurutan (kecuali lapisan *input*), setiap element pengolah (*neuron*) menjumlahkan setiap masukan dan melewatkannya pada fungsi aktivasi untuk mendapatkan *outputnya*. *Output* ini disebar maju ke lapisan selanjutnya secara berurutan, untuk kemudian mengalami proses yang sama sampai pada lapisan *output*. Lapisan *output* jaringan kemudian menghasilkan keluaran jaringan secara keseluruhan. Jadi arah sebaran informasi adalah lapisan *input-hidden-output*.

Tahapan propagasi balik dimulai dengan membandingkan respon jaringan keseluruhan dengan *output* yang diinginkan. Perbedaan yang terjadi atau *error*nya kemudian dipergunakan untuk memperbaiki harga pembobot jaringan.

Algoritma ini banyak dipakai pada aplikasi pengendalian karena prosedur belajarnya didasarkan pada hubungan yang sederhana, jika *output* memberikan hasil yang salah, maka pembobot dikoreksi supaya *error* dapat diperkecil dan respon jaringan selanjutnya diharapkan akan lebih mendekati harga yang benar.

### **3.8. Inisialisasi Bobot Awal Secara Random**

Pemilihan bobot awal sangat mempengaruhi jaringan syaraf dalam mencapai minimum global (atau mungkin hanya lokal saja) terhadap nilai *error*, serta cepat tidaknya proses pelatihan menuju kekonvergenan. Apabila nilai bobot awal terlalu besar, maka *input* kesetiap lapisan tersembunyi atau lapisan *output* akan jatuh pada daerah dimana **turunan** fungsi sigmoidnya akan kecil. Sebaliknya apabila nilai bobot awal terlalu kecil, maka **input** ke setiap lapisan tersembunyi atau lapisan *output* akan sangat kecil, yang akan menyebabkan proses pelatihan akan berjalan sangat lambat. Biasanya bobot awal diinisialisasi secara random antara -0,5 sampai 0,5 (atau -1 sampai 1, atau interval yang lain).

### **3.9. Perhitungan Bobot dengan *Backpropagation***

Misalkan kita akan mencari bobot hari selasa, maka data yang di gunakan untuk pembelajaran dengan *backpropagation* adalah data beban hari selasa sebelumnya atau dalam skripsi ini yang di pakai hari selasa selama satu bulan



sebelumnya (tidak ada ketentuan yang mengatur data tanggal mana yang harus diambil untuk suatu prakiraan tertentu).

Karena *backpropagation* menggunakan fungsi sigmoid biner maka range input adalah [0 1], sehingga data beban perlu di normalisasi, dengan rumus sebagai berikut :

- Normalisasi untuk data beban :

$$\text{Normalisasi} = \frac{\text{beban} - \text{bebanMin}}{\text{bebanMax} - \text{bebanMin}} \dots\dots\dots(3.1)$$

Proses normalisasi dilakukan didalam program, artinya data yang dipakai sebagai *inputan* adalah data normal (bukan data normalisasi) dan setelah itu program akan melakukan proses normalisasi secara otomatis.

### 3.9.1 Algoritma pembelajaran *Backpropagation*

- Inisialisasi bobot ( ambil bobot awal dengan nilai random yang cukup kecil )
- Tetapkan masimum Epoch, Target Error, dan Learning Rate
- Kerjakan langkah-langkah berikut (Epoch < Maksimum Epoch) dan (MSE > Target Error)

1. Untuk tiap-tiap pasangan elemen yang akan dilakukan pembelajaran,

kerjakan :

**Feedforward**

a. Tiap-tiap *input* ( $X_i, i = 1,2,3,\dots,n$ ) menerima sinyal  $x_i$  dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya (*Hidden layer*)

$X_i$  : masukan pada lapisan masukan

b. Tiap-tiap unit tersembunyi ( $Z_j, j = 1,2,3,\dots,p$ ) menjumlahkan sinyal-sinyal *input* berbobot :

$$Z\_in_j = V_{o_j} + \sum_{i=1}^n x_i v_{ij} \dots\dots\dots(3.2)$$

$Z$  : hidden unit (unit tersembunyi)

$V_{oj}$  : bias untuk hidden sel  $j$

$V_{ij}$  : bobot antara sel  $i$  pada lapisan masukan ke sel  $j$  pada

Lapisan tersembunyi

$V$  : bobot antara  $X$  dan  $Z$

$W$  : bobot antara  $X$  dan  $Y$

gunakan fungsi aktivasi untuk menghitung sinyal *output* :

$$Z_j = f(z\_in_j) \dots\dots\dots(3.3)$$

$Z_j$  : keluaran dari sel  $j$  pada lapisan tersembunyi dan merupakan masukan untuk sel  $k$  pada lapisan keluaran

dan kirimkan sinyal tersebut kesemua unit lapisan di atasnya (unit-unit *output*)

- e. Tiap-tiap unit *output* ( $Y_k, k = 1,2,3,\dots,m$ ) menjumlahkan sinyal *input-input* berbobot :

$$y_{in_k} = W_{o_k} + \sum_{i=1}^p Z_i W_{jk} \dots\dots\dots(3.4)$$

$W_{ok}$  : bias untuk unit keluaran sel k

$W_{jk}$  : bobot antara hidden sel j dan output sel k

$Z_j$  : keluaran dari sel j pada lapisan tersembunyi dan merupakan masukan untuk sel k pada lapisan keluaran

gunakan fungsi aktivasi untuk menghitung sinyal *outputnya* :

$$y_k = f(y_{in_k}) \dots\dots\dots(3.5)$$

$Y_k$  : keluaran jaringan pada sel k

dan kirimkan sinyal tersebut ke semua unit lapisan di atasnya ( unit-unit *output* ).

**Backfoward**

- d. Tiap-tiap unit *output* ( $Y_k, k = 1,2,3,\dots,m$ ) menerima target pola yang berhubungan dengan pola *input* pembelajaran, hitung informasi *errornya* :

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \dots\dots\dots(3.6)$$

$t_k$  : target pada sel k

$Y_k$  : keluaran jaringan pada sel k

$f'$  : turunan pertama fungsi sigmoid terhadap potensial aktifasinya

kemudian menghitung koreksi bobot (yang nantinya akan digunakan untuk memperbaiki nilai  $W_{jk}$ ) :

$$\Delta W_{jk} = \alpha \delta_k Z_j \dots \dots \dots (3.7)$$

$\alpha$  : learning rate

$\delta_k$  : faktor koreksi error pada lapisan keluaran untuk sel k  $Z_j$  : keluaran dari sel j pada lapisan tersembunyi dan merupakan masukan untuk sel k pada lapisan keluaran

hitung juga koreksi bias (yang nantinya akan digunakan untuk memperbaiki nilai  $W_{ok}$ ) :

$$\Delta W_{ok} = \alpha \delta_k \dots \dots \dots (3.8)$$

$\alpha$  : learning rate

$\delta_k$  : faktor koreksi error pada lapisan keluaran untuk sel k

- e. Tiap-tiap *input* tersembunyi ( $Z_j, j = 1, 2, 3, \dots, p$ ) menjumlahkan delta *inputnya* ( dari unit-unit yang berada pada lapisan diatasnya ) :

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \dots \dots \dots (3.9)$$

$\delta_k$  : faktor koreksi error pada lapisan keluaran untuk sel k

$W_{jk}$  : bobot antara hidden sel j dan output sel k

kalikan nilai ini dengan turunan dari fungsi aktifasinya untuk menghitung informasi *error* :

$$\delta_j = \delta_{in_j} f'(Z_{in_j}) \dots \dots \dots (3.10)$$

$\delta_j$  : faktor koreksi error pada lapisan tersembunyi untuk sel j

$f'(z_{in_j})$  : turunan pertama fungsi sigmoid terhadap potensial  
aktifasi lapisan tersembunyi

kemudian hitung koreksi bobot (yang nantinya akan digunakan  
untuk memperbaiki nilai  $V_{ij}$ ) :

$$\Delta W_{jk} = \alpha \delta_j x_k \dots\dots\dots(3.11)$$

$\alpha$  : learning rate

$\delta_j$  : faktor koreksi error pada lapisan tersembunyi untuk sel j

$X_k$  : masukan pada lapisan masukan

hitung juga koreksi bias (yang nantinya akan digunakan untuk  
memperbaiki nilai  $V_{oj}$ ) :

$$\Delta V_{oj} = \alpha \delta_j \dots\dots\dots(3.12)$$

$\alpha$  : learning rate

- f. Tiap-tiap unit *output* ( $Y_k, k = 1,2,3,\dots,m$ ) memperbaiki bias dan  
bobotnya ( $j = 0,1,2,3,\dots,p$ ) :

$$W_{jk} (baru) = W_{jk} (lama) + \Delta W_{jk} \dots\dots\dots(3.13)$$

Tiap-tiap unit tersembunyi ( $Z_j, j = 1,2,3,\dots,p$ ) memperbaiki bias dan  
bobotnya ( $i = 0,1,2,3,\dots,n$ ) :

$$V_{ij} (baru) = V_{ij} (lama) + \Delta V_{ij} \dots\dots\dots(3.14)$$

2. Tes kondisi berhenti


### 3.10 Peramalan Beban Jangka Pendek Dengan Mengetahui Model Dari *INSPIRASI-BIO*

Baru-baru ini, metode dari inspirasi-bio untuk problem solving, seperti *artificial neural network* (ANN) atau *genetic and evolutionary algorithms* (GEAs), telah menjadi semakin diterima sebagai pendekatan alternatif terhadap peramalan, sehubungan dengan keuntungan seperti pembelajaran non linear dan pencarian adaptif. Penelitian sekarang melaporkan penggunaan teknik ini untuk peramalan beban jangka pendek, di mana terdapat kebutuhan terhadap system dengan kemampuan menjawab cepat. Perbandingan di antara pendekatan konvensional dan inspirasi-bio (*Exponential Smoothing*), menunjukkan kinerja ramalan yang lebih baik untuk model evolusioner dan connectionist.

Peramalan beban jangka pendek muncul dari bidang artificial intelligence, di mana terdapat trend untuk melihat pada sifat inspirasi. Secara khusus, studi tentang nervous system dan evolusi biologis mempengaruhi alat-alat yang kuat, seperti *artificial neural network* (ANN) dan *genetic evolutionary algorithms* (GEAs), digunakan secara luas dalam problem engineering dan ilmu pengetahuan, seperti yang ada pada optimisasi gabungan dan numeric.

Artificial neural networks (ANN) dibentuk oleh unit pemrosesan sederhana, neuron di mana dihubungkan dalam jaringan oleh kekuatan synaptic, di mana pengetahuan yang dibutuhkan disimpan. Orang dapat menemukan sebuah keleidoskop dari ANN berbeda, di mana berbeda dalam beberapa ciri, seperti paradigma pembelajaran atau arsitektur internal. Dalam *Feedforward Neural Network* (FNN), neuron dikelompokkan ke dalam lapisan dan hanya terdapat hubungan forward. Ini memberikan sebuah arsitektur yang kuat, kemampuan pembelajaran dalam beberapa bentuk pemetaan non linear kontinyu, FNN

biasanya dilatih oleh algoritma keturunan gradient, FNN dapat melakukan peramalan satu langkah ke depan dengan memasukkan input dengan nilai  $n$  masa lalu. Sedangkan ANN itu sendiri adalah Suatu model yang meniru syaraf pusat untuk memprediksikan beban listrik untuk periode menit, jam, hari dan minggu. yang mempunyai kemampuan pembelajaran nonlinier, ramalan beban jangka pendek memainkan peranan penting dalam control real time dan fungsi keamanan dari sistem manajemen energi, ANN ramalan beban jangka pendek tradisional dapat diklasifikasikan sebagai time series atau model regresi. Model time series menggunakan *beban historis* untuk ekstrapolasi agar memperoleh beban perjam dimasa mendatang. model ini mengasumsikan bahwa trend beban data abnormal sebagai data buruk. *kerugian* dari model ini adalah bahwa informasi cuaca atau beberapa faktor lainnya yang memberikan kontribusi terhadap perilaku beban yang tidak digunakan secara penuh. kerugian utama adalah bahwa model ini membutuhkan teknik permodelan kompleks dan usaha perhitungan besar untuk memberikan hasil yang cukup akurat. ANN diaplikasikan untuk menghubungkan informasi cuaca dan variasi beban yang guna meramalkan beban puncak, total beban dan beban perjam. **Keuntungan** dari ANN terhadap model statistik pada kemampuannya untuk memodel asumsi dependensi kompleks di antara variabel-variabel input. Selanjutnya, ANN menyampaikan hubungan non linear implisit diantara variabel-variabel input. Sebuah *Artificial Neural Network* (ANN) mempunyai struktur pemrosesan paralel dan terdistribusi. Sebuah ANN terdiri dari elemen-elemen pemrosesan yang disebut dengan neuron. Neuron ini berhubungan secara unidimensional.



Gambar.3.15. *Feedforward Neural Nertwork ( FNN )*

### 3.11 Teori *Genetic Evolutionary Algorhythms*

Genetic and evolutionary algorithms (GEAs) digunakan untuk memberi nama pada sebuah keluarga prosedur perhitungan di mana jumlah solusi potensial terhadap problem dilakukan dengan melibatkan populasi, Dan GEAs ini difungsikan atau digunakan untuk permasalahan optimasi dimana melepas seluruh kemungkinan solusi yang membutuhkan perhitungan besar, Masing-masing individual membuat kode solusi dalam string (kromosom) dari simbol (gen), diberikan nilai numerik (kesesuaian), yang digunakan untuk mengukur kualitas solusi. Solusi baru diciptakan melalui aplikasi operator genetic (khususnya persilangan atau mutasi). Proses keseluruhan terlibat melalui bias seleksi stochastic yang cocok dengan individual pada kesesuaian lebih tinggi. Penelitian dalam mengaplikasikan *GEAs* kepada peramalan sangatlah langka.walaupun terdapat beberapa publikasi pada area ini, jumlahnya sedikit atau tidak dapat terlihat.



## BAB IV


### ANALISIS PRAKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL *BIO-INSPIRED* DENGAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORITHM*S

#### 4.1 DATA BEBAN

Dalam penulisan skripsi ini diperlukan data empiris berupa data beban tiap jam. Untuk itu diperlukan sebuah lokasi studi kasus untuk mendapatkan data tersebut. Dengan mempertimbangkan berbagai faktor seperti letak lokasi, tegangan yang dihasilkan, arus yang dapat disalurkan dan lain-lain, maka lokasi yang diambil adalah Gardu Induk Sengkaling Malang.

Gardu Induk Sengkaling Malang memiliki Empat buah Trafo dengan tujuh penyulang yang terdiri dari :

1. Trafo 1 dan 2 bertegangan 150/70 kV dengan daya 30 MVA digunakan untuk melayani atau mensuplai G.I Blimbing
2. Trafo 3 bertegangan 150/20 kV dengan daya 30 MVA
  - ❖ Penyulang Wastra Indah
  - ❖ Penyulang Pujon
  - ❖ Penyulang karang Ploso
  - ❖ Penyulang Junrejo
3. Trafo 4 bertegangan 150/20 kV dengan daya 30 MVA
  - ❖ Penyulang Dinoyo
  - ❖ Penyulang Batu
  - ❖ Penyulang Selecta



Gambar 4.1  
Diagram Single Line Gardu Induk Sengkaling Malang

#### 4.2. Program komputer Metode *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms*

Untuk pemecahan masalah perkiraan beban digunakan bantuan program komputer. Program komputer ini sangat berguna untuk mempercepat proses perhitungan yang membutuhkan tingkat ketelitian yang tinggi dan sering melibatkan iterasi yang memerlukan waktu yang lama dan hampir tidak mungkin bila dikerjakan secara manual.

Dalam hal ini program yang digunakan adalah bahasa pemrograman Matlab 6.5.1, yang merupakan bahasa pemrograman yang sudah sering digunakan baik untuk peramalan beban sendiri maupun program program yang lain.

#### 4.3. Algoritma Program *Artificial Neural Networks* dan *Genetic Evolutionary*

##### *Algorithms*

Algoritma *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* dalam memperkirakan beban secara umum adalah sebagai berikut:


1. Menentukan inputan data untuk *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* pada Excel Berupa data historisis beban.
2. Pada Matlab variabel mengambil file dari Excel, dengan mengambil baris dan kolom excel dan dimasukkan dalam variabel *Train* dan *Ramal*.
3. Pembentukan matrik untuk *nnInput*, *nnOutput* dan *nnRamal*..
4. Membentuk jaringan (*net1*) *feedforward* dengan dua lapisan.  
Lapisan pertama (lapisan tersembunyi) terdiri dari 24 *neuron* dengan fungsi aktifasi *logsig*. Sedangkn lapisan kedua (lapisan output) hanya berisi 1 *neuron* dengan fungsi aktifasi *purelin*.
5. Menentukan maksimum epoh.  
Merupakan jumlah iterasi untuk melatih jaringan, dengan maksium epoh sebanyak 800000.
6. Menentukan kinerja tujuan (*Goal*).  
Iterasi akan dihentikan bila nilai fungsi kinerja kurang dari atau sama dengan kinerja tujuan yaitu 0,001.
7. Menentukan *Learning Rate*.  
Laju pembelajaran diset pada nilai 0,95.
8. Menentukan rasio untuk menaikkan *Learning Rate*.


Digunakan sebagai faktor pengali untuk menaikkan *Learning Rate* apabila nilai yang ada terlalu rendah untuk mencapai nilai yang konvergen. Dan diset pada nilai 1,01.

9. Menentukan rasio untuk menurunkan *Learning Rate*.

Digunakan sebagai faktor pengali untuk menurunkan *Learning Rate* apabila nilai yang ada terlalu tinggi dan menuju ke ketidakstabilan. Dan diset pada nilai 0,75.

10. Proses *training* pada net1 untuk *nnInput* dan *nnOutput*.
11. Melihat bobot input, lapisan dan bias.
12. Simulasi hasil.
13. Grafik perbandingan antara target dan *training*.






Gambar 4-2  
Program Artificial Neural Networks dan Genetic Evolutionary Algorithms

#### 4.4. Penentuan Arsitektur Jaringan

Untuk perkiraan beban menggunakan jaringan syaraf tiruan digambarkan sebagai berikut:



Gambar 4-3  
Arsektetur Jaringan untuk perkiraan beban

Arsektektur ini berfungsi sebagai visualisasi dari Jaringan Syaraf Tiruan yang digunakan. Dengan bantuan dari arsektektur ini maka kita akan mendapatkan informasi mengenai jumlah neuron pada lapisan input, hidden, dan outoput. Selaian itu kita juga akan mendapatkan alur kerja dari proses yang berlangsung. Dari arsitektur jaringan diatas didapatkan informasi 2 neuron pada lapisan input, 4 neuron pada lapisan hidden dan saja 1 neuron untuk lapisan output. Untuk pemakaian jumlah neuron pada hidden layer, operator dapat menentukan berupa saja jumlah neuron asalkan pada prosesnya dapat membentuk outputan yang mendekati nilai target dan error yang dihasilkan dapat mendekati error target. Jika kondisi tersebut terpenuhi, maka pada tahap training dengan metode pembelajaran Backproagation dapat dihasilkan bobot, yang nantinya akan digunakan untuk perhitungan pada tahap perkiraan.


Karena dalam penulisan ini menggunakan metode pembelajaran Backproagation dengan fungsi sigmoid biner maka data inputan perlu dinormalisasi terlebih dahulu dengan nilai yang terletak antara 0 sampai dengan 1 agar didapat output dalam bentuk biner. Dengan rumusan sebagai berikut:

$$\text{Normalisasi} = \frac{\text{beban} - \text{bebanMax}}{\text{bebanMax} - \text{bebanMin}} \times 100,$$

Pada program MATLAB 6.5.1, proses normalisasi terjadi didalam program tanpa ada bentuk tampilannya.

Terdapat pula parameter-parameter dalam proses pembelajarannya, diantaranya: learning rate, Momentum  $\eta$ , Bobot awal hidden ke output ke hidden, bobot awal dari bias ke hidden, bobot awal hidden ke output dan bobot awal bias ke output, Alpha Incremental, Alpha Decremental.

4.4.1. Diagram Alir Pemrosesan Bobot input Menjadi Output pada Backpropagation



Gambar 4-4  
Diagram alir backpropagation

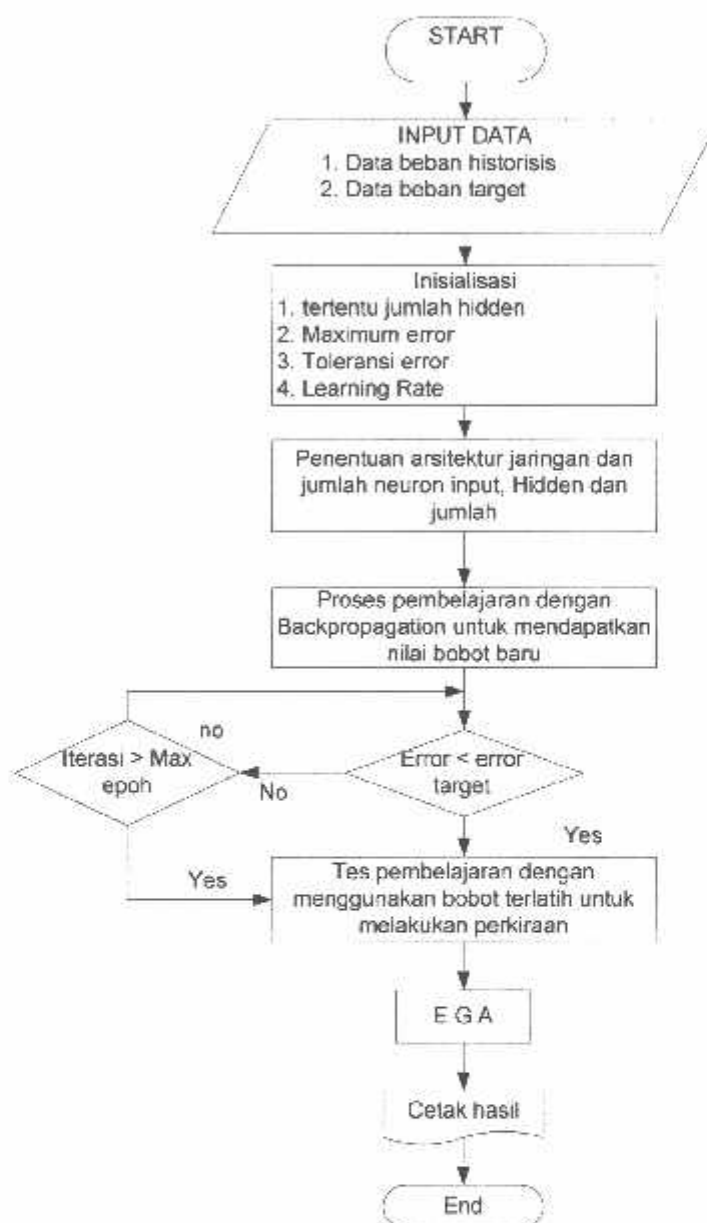


Simbol – simbol yang digunakan pada algoritma training untuk jaringan

Backpropagation adalah sebagai berikut:

- X Data training untuk input ;  $x = (x_1, \dots, x_i, \dots, x_n)$
- t Data training output (target/desired output),  $t = (t_1, \dots, t_k, \dots, t_m, \dots)$
- $\alpha$  Learning rate yaitu parameter yang mengontrol perubahan bobot selama pelatihan. Jika learning rate besar, jaringan semakin cepat belajar, tetapi hasilnya kurang akurat. Learning rate, biasanya, dipilih antara 0 dan 1.
- $X_i$  Unit input ke-i. untuk unit input, sinyal yang masuk dan keluar pada suatu unit dilambangkan dengan variable yang sama, yaitu  $x_i$ .
- $Z_j$  Hidden unit ke-j. Sinyal input pada  $Z_j$  dilambangkan dengan  $z_{inj}$ . Sinyal output (aktivasi) untuk  $Z_j$  dilambangkan dengan  $Z_j$ .
- $V_{0j}$  Bias untuk hidden unit ke-j.
- $V_{ij}$  Bobot antara unit input ke-l dan hidden unit ke-j.
- $Y_k$  Unit output ke-k. Sinyal input ke  $Y_k$  dilambangkan  $Y_{ink}$ . Sinyal output (aktivasi) untuk  $Y_k$ , dilambangkan dengan  $Y_k$ .
- $W_{0k}$  Bias untuk unit output ke-k.
- $W_{jk}$  Bobot antara hidden unit ke-j dan unit output ke-k.
- $\delta_k$  Faktor koreksi error untuk bobot  $w_{jk}$ .
- $\delta_j$  Faktor koreksi error untuk bobot  $v_{ij}$ .
- $\eta$  Momentum, untuk mempertimbangkan kecenderungan yang terjadi pada permukaan error dengan diikuti parameter penyeimbanya yaitu Alpha incremental dan Alpha decremental.

4.4.2. Diagram Alir Perkiraan Beban listrik Dengan *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms*



Gambar 4.5  
Diagram alir perkiraan beban listrik dengan *Artificial Neural Networks*  
dan *Genetic Evolutionary Algorithms*

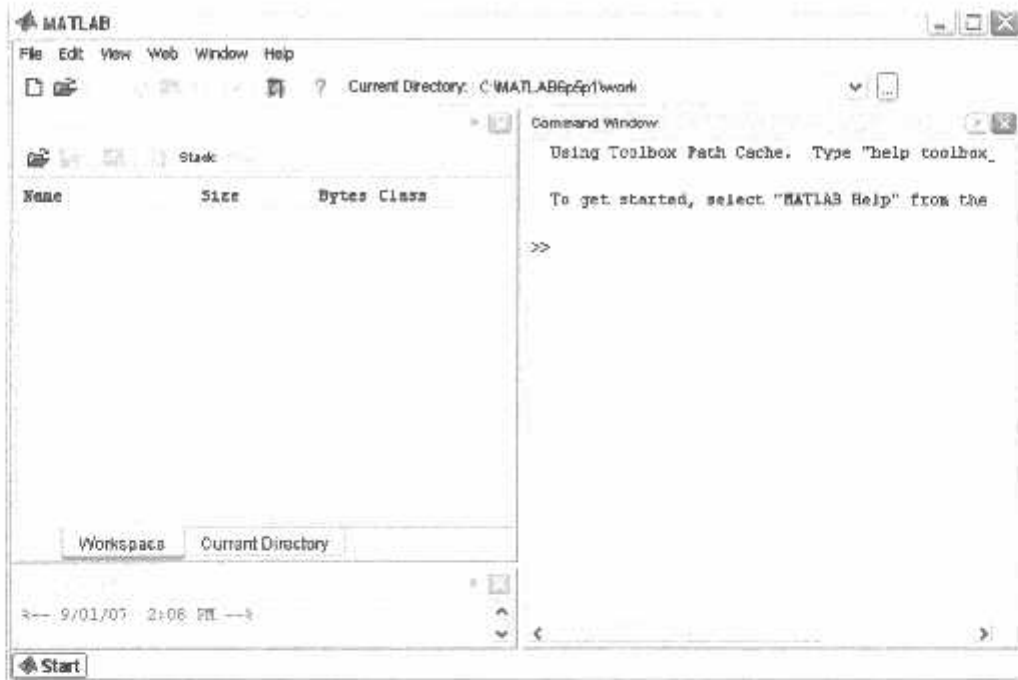
**4.5. Prosedur Pelaksanaan Program Hasil Perkiraan Data Parameter Untuk Inputan G.I Sengkaling**  
 Program Dalam Skripsi ini Dijalankan Dengan Menggunakan Bahasa Pemrograman MATLAB 6.5.1

1. Data Inputan

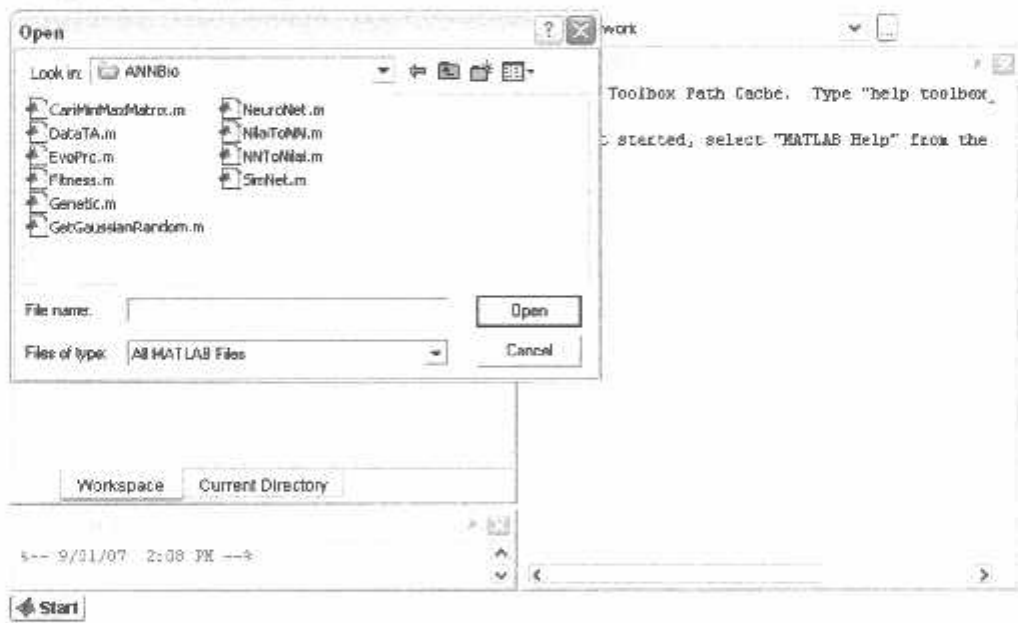
jam	rabu 1 november 2006																							aktual																		
	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10	t11	t12	t13	t14	t15	t16	t17	t18	t19	t20	t21	t22	t23		t24																	
0:00	37,60	36,30	35,00	34,85	34,70	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40		
1:00	36,30	35,00	34,85	34,70	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30
2:00	35,00	34,85	34,70	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30	
3:00	34,85	34,7	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30		
4:00	34,70	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30			
5:00	33,90	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30				
6:00	33,10	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30					
7:00	41,30	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30						
8:00	49,50	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30							
9:00	44,00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30								
10:00	38,50	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30									
11:00	38,30	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30										
12:00	38,10	38,20	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30											
13:00	38,20	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30													
14:00	38,30	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30													
15:00	38,50	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30														
16:00	38,70	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30															
17:00	44,90	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																
18:00	58,30	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																	
19:00	58,90	58,30	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																		
20:00	58,10	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																				
21:00	56,50	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																					
22:00	47,00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																						
23:00	43,55	40,10	36,45	32,80	34,75	36,70	36,30	35,90	35,60	35,30	35,20	35,10	34,05	33,00	35,70	38,40	39,75	41,10	43,30																							

Tabel 1  
 Data Parameter Untuk Inputan G.I Sengkaling

## 2. Tampilan menu utama program



↓ Tekan open file, pilih DataTA



Gambar 4.6  
Menu Utama Program

### 3. Tampilan Program Artificial Neural Nertwork dan Genetic Evolutionary Algorithms



```
1 | %Program Tutorial efisiensi untuk Scripts
2 | %pada Topik Evolusi Intelektual Teknologi Nasional Malang
3 |
4 | clear
5 | interface=ddesim('model', 'Data1.xlsx');
6 | train=ddeseq(interface, '200212114628');
7 | Ansatz=ddeseq(interface, '2002121702');
8 | Loadmax=18;
9 | Loadmin=65;
10 | x=train(:,1);
11 | rowT=length(x);
12 | x=train(1,:);
13 | colT=length(x);
14 | %=zeros(1,1);
15 | %row=length(x);
16 | %col=length(1,);
17 | %col=length(x);
18 | nnInp=zeros(rowT,24);
19 | nnOut=zeros(rowT,1);
20 | %nnInp=zeros(rowT,1);
21 | for i=1:rowT
22 |     j=1:24
23 |         nnInp(i,j)=ddesimToNN(train(i,:),Loadmin,Loadmax);
24 |     end
25 |     nnOut(i,1)=ddesimToNN(train(i,:),Loadmin,Loadmax);
26 | end
27 | %for i=1:rowT
```

Gambar 4.7  
Program Artificial Neural Nertwork dan Genetic Evolutionary Algorithms


4. Kemudian pilih Run atau tekan tombol F5 untuk menjalankan program




```
1 | %Program
2 | %pada Topik Evolusi Intelektual Teknologi Nasional Malang
3 |
4 | clear
5 | interface=ddesim('model', 'Data1.xlsx');
6 | train=ddeseq(interface, '200212114628');
7 | Ansatz=ddeseq(interface, '2002121702');
8 | Loadmax=18;
9 | Loadmin=65;
10 | x=train(:,1);
11 | rowT=length(x);
12 | x=train(1,:);
13 | colT=length(x);
14 | %=zeros(1,1);
15 | %row=length(x);
16 | %col=length(1,);
17 | %col=length(x);
18 | nnInp=zeros(rowT,24);
19 | nnOut=zeros(rowT,1);
20 | %nnInp=zeros(rowT,1);
21 | for i=1:rowT
22 |     j=1:24
23 |         nnInp(i,j)=ddesimToNN(train(i,:),Loadmin,Loadmax);
24 |     end
25 |     nnOut(i,1)=ddesimToNN(train(i,:),Loadmin,Loadmax);
26 | end
27 | %for i=1:rowT
```

Gambar 4.8  
Running Program Artificial Neural Nertwork dan Genetic Evolutionary Algorithms


## 5. Tampilan Proses Training




Grafik 4.1  
Proses Training Aplikasi Program ANN-GEAs Pada Epochs 225



Grafik 4.2  
Proses Training Aplikasi Program ANN-GEAs Pada Epochs 466950



Grafik 4.3  
Proses Training Aplikasi Program ANN-GEAs Pada Epochs 636564



Grafik 4.4  
Hasil Proses Training Dengan Perbandingan antara Target dan Output

#### 4.6. Analisa Hasil Training

Dari hasil proses training , pada epoch 636564 nilai MSE nya adalah 800000 ini artinya nilai MSE atau Goalnya sudah terpenuhi, dimana nilai MSE nya adalah sebesar = 0.001, (pada *command windows Matlab* tertulis = TRAINGDM, Epoch 636564/800000, MSE 0.001/0.001, Gradient 1.23082e-005/1e-010, ini akan menghasilkan data yang akurat. Pada grafik 4-1 sampai dengan grafik 4-3 terlihat bahwa turunnya

grafik sangat terlihat jelas, ini dikarenakan parameter learning rate (laju pembelajaran) pada program diset = 0.95 (pada perintah *net1.trainParam.lr=0.95;*) .Jika learning rate besar, jaringan semakin cepat belajar, tetapi hasilnya kurang akurat. Learning rate, biasanya, dipilih antara 0 sampai 1, selain itu ada parameter nilai rasio untuk menaikkan learning rate, rasio ini berguna sebagai faktor pengali untuk menaikkan learning rate apabila learning rate yang ada terlalu rendah untuk mencapai kekonvergenan , pada program diset =1.01 , ( pada perintah *net1.trainParam.lr\_inc=1.01;* ). Selain itu juga diperlukan rasio untuk menurunkan learning rate, rasio ini berguna sebagai faktor pengali untuk menurunkan learning rate apabila learning rate yang ada terlalu tinggi dan menuju ketidakstabilan , pada program diset =0.99 , ( pada perintah *net1.trainParam.lr\_dec=0.99;*). Sehingga dari semua parameter itu mengakibatkan program berjalan stabil menuju kekonvergenan , dengan hasil yang akurat tetapi juga memerlukan waktu yang relatif lama. Ini terlihat pada grafik 4-4 yaitu perbandingan antara target dan training, tidak jauh beda.


#### **4.7. Hasil Perkiraan Beban Listrik**

Prakiraan beban listrik perjam dilakukan untuk mendapatkan error beban prakiraan terhadap beban aktual dalam satu hari selama satu minggu, adapun perbandingan hasil perkiraan dapat di tampilkan sebagai berikut :



Tabel 4-2  
Perbandingan Hasil Perkiraan Pada Hari Rabu, 1 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	40.10	40.79	1.72
1:00	36.45	37.76	3.60
2:00	32.80	34.45	5.02
3:00	34.75	33.13	4.66
4:00	36.70	37.64	2.57
5:00	36.30	36.29	0.02
6:00	35.90	36.83	2.58
7:00	35.60	36.97	3.86
8:00	35.30	37.26	5.52
9:00	35.20	35.67	1.35
10:00	35.10	36.00	2.56
11:00	34.05	34.44	1.15
12:00	33.00	33.98	2.98
13:00	35.70	34.37	3.72
14:00	38.40	37.13	3.30
15:00	39.75	39.21	1.35
16:00	41.10	40.40	1.70
17:00	43.30	42.85	1.05
18:00	59.50	61.09	2.68
19:00	60.20	59.89	0.51
20:00	58.70	58.86	0.27
21:00	54.50	55.60	2.01
22:00	47.90	48.26	0.74
23:00	44.05	44.03	0.05
MAPE RATA - RATA			0.034



Grafik 4.5  
Hasil Perbandingan prakiraan beban Rabu, 1 Desember 2006

Tabel 4-3  
Perbandingan Hasil Perkiraan Pada Hari Kamis, 2 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	40.20	40.25	0.12
1:00	38.50	38.56	0.14
2:00	36.80	36.92	0.33
3:00	38.15	36.96	3.12
4:00	39.50	39.11	0.98
5:00	37.35	38.59	3.33
6:00	35.20	34.92	0.79
7:00	34.95	34.82	0.36
8:00	34.70	34.92	0.62
9:00	36.50	35.35	3.14
10:00	38.30	38.31	0.02
11:00	37.20	38.75	4.16
12:00	36.10	36.78	1.89
13:00	35.75	36.82	2.99
14:00	35.40	36.02	1.76
15:00	37.45	36.78	1.79
16:00	39.50	38.90	1.52
17:00	45.10	44.35	1.67
18:00	59.40	60.36	1.61
19:00	59.50	60.26	1.27
20:00	58.10	58.68	1.00
21:00	55.80	54.19	2.89
22:00	45.60	48.83	7.07
23:00	41.15	40.88	0.67
MAPE RATA - RATA			0.016



Grafik 4.6  
Hasil Perbandingan prakiraan bban Kamis, 2 Desember 2006

Tabel 4-4  
Perbandingan Hasil Perkiraan Pada Hari Jumat, 3 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	36.70	38.99	6.23
1:00	38.60	35.36	8.39
2:00	40.50	38.89	3.98
3:00	38.75	40.90	5.55
4:00	37.00	38.04	2.82
5:00	35.65	35.55	0.27
6:00	34.30	35.45	3.37
7:00	34.25	34.04	0.63
8:00	34.20	34.32	0.36
9:00	35.30	35.40	0.28
10:00	36.40	36.48	0.21
11:00	37.25	36.65	1.61
12:00	38.10	37.70	1.04
13:00	36.55	37.87	3.61
14:00	35.00	35.94	2.69
15:00	35.50	36.34	2.37
16:00	36.00	37.77	4.93
17:00	41.30	39.71	3.85
18:00	58.20	58.71	0.88
19:00	59.00	59.73	1.24
20:00	59.10	58.75	0.58
21:00	56.80	54.00	4.93
22:00	47.60	47.68	0.26
23:00	44.15	42.20	4.41
<b>MAPE RATA - RATA</b>			<b>0.187</b>



Grafik 4.7  
Hasil Perbandingan prakiraan beban Hari Jumat, 3 Desember 2006

Tabel 4-5  
Perbandingan Hasil Perkiraan Pada Hari Sabtu, 4 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	40.50	40.68	0.45
1:00	40.50	39.49	2.48
2:00	40.50	39.87	1.55
3:00	41.25	40.77	1.17
4:00	42.00	41.11	2.11
5:00	37.75	39.65	5.03
6:00	33.50	35.01	4.50
7:00	33.15	32.93	0.66
8:00	32.80	33.68	2.67
9:00	33.15	33.56	1.24
10:00	33.50	33.87	1.12
11:00	33.35	33.58	0.68
12:00	33.20	33.22	0.05
13:00	31.80	33.11	4.13
14:00	30.40	31.59	3.92
15:00	32.05	32.03	0.06
16:00	33.70	34.20	1.48
17:00	39.30	38.01	3.28
18:00	57.10	56.92	0.32
19:00	56.90	59.03	3.74
20:00	58.30	57.88	0.72
21:00	52.50	54.19	3.23
22:00	46.50	46.12	0.81
23:00	42.25	43.82	3.72
MAPE RATA - RATA			0.035



Grafik 4.8  
Hasil Perbandingan prakiraan beban Sabtu, 4 Desember 2006

Tabel 4-6  
Perbandingan Hasil Perkiraan Pada Hari Minggu, 5 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	38.00	37.96	0.10
1:00	36.75	37.47	1.95
2:00	35.50	36.62	3.15
3:00	36.20	37.06	2.38
4:00	36.90	36.49	1.12
5:00	36.05	35.95	0.27
6:00	35.20	34.69	1.45
7:00	36.00	34.99	2.81
8:00	36.80	36.04	2.06
9:00	39.20	37.74	3.72
10:00	41.60	39.94	3.98
11:00	40.85	41.23	0.94
12:00	40.10	39.83	0.68
13:00	40.40	39.76	1.58
14:00	40.70	40.69	0.03
15:00	40.75	40.73	0.04
16:00	40.80	39.31	3.65
17:00	41.00	43.70	6.58
18:00	56.80	55.23	2.77
19:00	58.80	58.80	0.01
20:00	57.50	58.04	0.93
21:00	52.60	53.89	2.45
22:00	47.40	46.88	1.11
23:00	43.05	43.90	1.97
MAPE RATA - RATA			0.008



Grafik 4.9  
Hasil Perbandingan prakiraan beban Minggu, 5 Desember 2006

Tabel 4-7  
Perbandingan Hasil Perkiraan Pada Hari Senin, 6 Desember 2006


jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	38.70	39.23	1.36
1:00	36.70	37.57	2.36
2:00	34.70	35.13	1.23
3:00	35.40	34.59	2.28
4:00	36.10	36.48	1.06
5:00	35.45	35.58	0.37
6:00	34.80	34.31	1.41
7:00	37.35	35.68	4.47
8:00	39.90	38.66	3.11
9:00	40.30	41.27	2.41
10:00	40.70	40.37	0.81
11:00	40.20	40.46	0.65
12:00	39.70	39.35	0.89
13:00	40.65	39.59	2.61
14:00	41.60	40.28	3.17
15:00	38.10	41.79	9.69
16:00	34.60	37.22	7.58
17:00	46.80	45.01	3.83
18:00	60.80	58.99	2.97
19:00	59.70	60.01	0.52
20:00	57.70	58.83	1.96
21:00	52.90	52.74	0.30
22:00	47.30	47.91	1.29
23:00	43.00	43.16	0.36
MAPE RATA - RATA			0.004



Grafik 4.10  
Hasil Perbandingan prakiraan beban Senin, 6 Desember 2006

Tabel 4-8  
Perbandingan Hasil Perkiraan Pada Hari Selasa, 7 Desember 2006

jam	AKTUAL	PRAKIRAAN	ERROR
	MW	MW	%
0:00	38.70	39.89	3.08
1:00	37.75	36.45	3.46
2:00	36.80	37.31	1.39
3:00	37.30	38.27	2.61
4:00	37.80	37.56	0.64
5:00	36.95	36.49	1.25
6:00	36.10	36.57	1.31
7:00	36.50	36.30	0.55
8:00	36.90	37.72	2.22
9:00	38.65	38.22	1.10
10:00	40.40	39.29	2.75
11:00	39.85	39.92	0.18
12:00	39.30	39.09	0.54
13:00	39.70	39.29	1.03
14:00	40.10	40.09	0.02
15:00	40.75	39.68	2.62
16:00	41.40	40.35	2.54
17:00	45.00	47.46	5.46
18:00	60.20	60.01	0.32
19:00	60.70	60.06	1.05
20:00	58.70	58.71	0.02
21:00	55.40	54.28	2.03
22:00	48.30	48.51	0.43
23:00	43.65	43.80	0.33
<b>MAPE RATA - RATA</b>			<b>0.006</b>



Grafik 4.11  
Hasil Perbandingan prakiraan beban Selasa, 7 Desember 2006

#### 4.8. Analisa Hasil Perkiraan

Pada tabel 4-1 sampai dengan 4-7 yaitu perkiraan beban pada tanggal 1 Desember 2006 sampai dengan 7 Desember 2006, Dengan menggunakan data jaringan pada saluran distribusi di Gardu Induk Sengkaling Malang, di peroleh hasil perkiraan beban selama satu minggu dengan MAPE minimum sebesar 0,01% MAPE maksimum sebesar 9,69% dan menghasilkan MAPE rata rata sebesar 0,053 % Dengan proses pelatihan yang akurat maka akan didapatkan hasil data prakiraan yang baik, tetapi ada pada jam-jam tertentu yang nilai errornya melebihi nilai rata-rata, diakibatkan pola data inputan dari PLN terdapat lonjakan beban ataupun penurunan beban yang melebihi normalnya. Hal ini disebabkan oleh berbagai macam faktor, misalkan pemadaman listrik karena perbaikan, gangguan dan lain-lain. Meskipun demikian hasil secara keseluruhan bisa dikatakan baik, ini dapat dilihat dari perbandingan antara prakiraan dan data beban yang sebenarnya tidak terlalu jauh beda, ini ditunjukkan dari MAPE yang relatif kecil dan juga ditunjukkan pada Grafik 4-5 sampai Grafik 4-11. Batas toleransi MAPE agar selisih beban tidak terlalu besar adalah kurang lebih 10 %. Oleh karena itu agar tercapai penyesuaian antara pembangkitan dengan permintaan daya, maka proses pelatihan yang akurat sangat diperlukan untuk didapatkan hasil prakiraan yang baik, dimana hasil antara prakiraan dan beban yang sebenarnya tidak terlalu jauh berbeda hal ini dapat dilihat dari MAPE yang relatif kecil



## BAB V

### KESIMPULAN DAN SARAN

#### 5.1. Kesimpulan

Setelah melakukan pengujian untuk memperkirakan beban dengan menggunakan metode *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms*, maka dapat ditarik kesimpulan sebagai berikut :

1. Berdasarkan hasil analisis, bahwa metode *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* dapat digunakan untuk perhitungan perkiraan beban listrik jangka pendek perjam atau harian.
2. Metode *Artificial Neural Networks* dan *Genetic Evolutionary Algorithms* dapat melakukan perkiraan beban tiap jam berdasarkan data beban G.I SENGKALING MALANG, yaitu perkiraan pada tanggal 1 November – 7 Desember 2006. Dengan menggunakan data jaringan pada saluran distribusi di Gardu Induk Sengkaling Malang, di peroleh hasil perkiraan beban selama satu minggu dengan MAPE minimum sebesar 0,01% MAPE maksimum sebesar 9,69% dan menghasilkan MAPE rata rata sebesar 0,053 %
3. Berdasarkan hasil perbandingan perkiraan pada tanggal 1 Desember – 7 Desember 2006 menunjukkan bahwa MAPE salah satunya menunjukkan ada kenaikan MAPE.

## 5.2. Saran

Sebaiknya pada saat kita melakukan analisa perkiraan beban, data yang digunakan harus cukup banyak, data ini akan mewakili nilai yang telah kita tentukan (target beban) sehingga nilai perkiraan mendekati nilai target tersebut. Karena hasil perkiraan akan mengikuti pola beban pada masa lalu.

Selain itu hal yang berpengaruh terhadap hasil proses perkiraan beban adalah data beban yang dipakai merupakan data beban dengan fluktuasi yang tajam atau kondisi beban tidak normal, ini disebabkan karena sering terjadinya pemadaman akibat gangguan atau perbaikan. Oleh karena itu sebaiknya kita menggunakan data beban dalam kondisi normal.

## DAFTAR PUSTAKA

- [1]. A.S.PABLA, **Sistem Distribusi Daya Listrik**. Erlangga
- [2]. Dr.Ir. Kuswara Setiawan, MT. **Paradigma Sistem Cerdas Artificial Intelegences, Edisi Pertama**, Bayu Media Publishing, Malang 2003
- [3]. Ir. Djiteng Marsudi **"Operasi Sistem Tenaga Listrik "Balai penerbit Dan Humas Institut Saint dan Teknologi Nasional, Jakarta 2003**
- [4]. Pohleim, Harmut. *GEA Toolbox: Genetic and Evolutionary Algorythms: Principles, Methods, and Algorythms.*  
<http://www.geatbx.com/docu/alginde.html>
- [5]. Sri Kusuma Dewi **"Artificial Intellegence " Graha Ilmu, Yogyakarta 2003**
- [6]. Sri Kusuma Dewi **"Membangun Jaringan Syaraf Tiruan Dengan Memakai Matlab Dan Exel Link" Graha Ilmu, Yogyakarta April 2004**



# LAMPIRAN

- LISTING PROGRAM
  - DATA BEBAN G.I SENGKALING
-

%Program Zainul effendi untuk Skripsi  
%pada Teknik Elektro Institut Teknologi Nasional Malang

```
clc
interface=ddcinit('excel','Data1.xls');
train=ddereq(interface,'r3c2:r2114c26');
%ramal=ddereq(interface,'r26c2:r27c32');
Loadmin=18;
Loadmax=65;
x=train(:,1);
rowT=length(x);
x=train(1,:);
colT=length(x);
%x=ramal(:,1);
%rowR=length(x);
%x=ramal(1,:);
%colR=length(x);
nnInp=zeros(rowT,24);
nnOut=zeros(rowT,1);
%nnRamal=zeros(rowR,31);
for i=1:rowT
    for j=1:24
        nnInp(i,j)=NilaiToNN(train(i,j),Loadmin,Loadmax);
    end
    nnOut(i,1)=NilaiToNN(train(i,25),Loadmin,Loadmax);
end
%for i=1:rowR
%    for j=1:31
%        nnRamal(i,j)=ramal(i,j);
%    end
%end
nnInp=nnInp';
nnOut=nnOut';
%nnRamal=nnRamal';
%-----
%net1=newff(minmax(nnInp),[31 1],{'logsig','purelin'},'trainlm');
%net1.trainParam.epochs=20000;
%net1.trainParam.goal=0.001;
%net1.trainParam.lr=0.3;
%-----
net1=newff(minmax(nnInp),[16 1],{'logsig','purelin'},'traingdm','learnngdm');
net1.trainParam.epochs=800000;
net1.trainParam.goal=0.001;
net1.trainParam.lr=0.95;
net1.trainParam.lr_inc=1.01;
net1.trainParam.lr_dcc=0.99;
net1.trainParam.mc=0.75;
%-----
```

---

```

net1.IW{1,1}=[...
-1.6650 0.8220 0.1330 -1.8254 -1.9942 1.0775 -0.2979 -2.4953
0.9708 -2.0187 ...
1.7350 -0.4033 -0.8807 -0.1406 -1.2579 0.9759 0.2989 -0.2350
2.4259 -1.0527 ...
-0.8231 -1.8113 0.8543 1.0919
0.5725 -0.4150 0.7548 -0.5528 0.0383 -0.3660 -0.0609 0.1805
0.0354 -0.1904 ...
0.3638 -0.5654 0.2896 0.2275 -0.0387 -0.1729 0.6149 -0.9094
0.9049 -0.2925 ...
0.4162 -0.9841 3.2120 -7.0217
4.4253 1.9586 1.2196 1.0699 -1.3681 1.3036 -2.3337 1.4683 -
1.9193 1.1270 ...
-0.1679 0.4595 -0.0794 -0.0900 -1.7567 2.1949 0.0289 -0.1100
0.4672 0.4476 ...
-0.7430 0.8368 0.9667 -0.7318
-1.9256 0.4976 -3.1571 0.8243 -1.5461 -2.7822 -3.1794 -0.2352 -
2.9346 -1.0362 ...
-1.4299 -2.5198 -2.1774 0.6481 0.0534 0.3109 -2.8297 -2.7641 -
1.9488 -3.0091 ...
-3.1512 -0.8254 -0.5128 -0.9224
-2.6917 -2.4483 -0.5888 -1.9240 -2.8275 -2.8490 -1.8672 -2.3009 -
3.0984 0.8120 ...
-2.4075 -1.1910 0.6831 -0.6110 -0.9597 -2.5776 -2.5707 -0.9946
0.7323 -2.3057 ...
-3.5197 0.2324 0.3861 -0.2667
-1.3668 -1.6257 0.7422 -2.3958 -2.6607 -2.4441 0.8285 -0.1565 -
2.4337 0.9174 ...
-3.4876 -1.3215 -2.9008 -2.3158 -2.1398 0.8960 -1.5321 -0.2209 -
1.2716 0.7503 ...
-0.8671 0.6635 -1.3961 -2.2098
0.7309 0.3213 2.4474 1.7028 -2.8799 0.5909 0.6249 -2.3749 -
1.1173 0.7040 ...
-2.5882 -0.0364 -0.4002 1.8400 -0.8659 -1.3623 -0.1387 -2.2748
0.3099 0.8280 ...
-2.4569 -0.3034 -0.7692 -2.4476
-3.0500 0.0015 -2.1253 -2.5109 -0.6065 -2.7544 -2.9108 -0.6097 -
1.0265 -2.6131 ...
0.5054 -0.2771 0.7001 -0.3772 -3.0359 -0.3170 -2.8599 0.6985 -
0.3747 -3.3177 ...
-1.1981 0.5070 -2.5538 -1.3545
0.3102 -0.1689 0.4550 1.5718 -2.3430 -1.6805 0.9337 -0.0142
0.3473 0.8268 ...
-1.4315 1.4980 1.4339 -1.9315 1.2412 0.1988 1.5180 1.0644
0.3390 -0.1669...
-2.0987 -0.5886 -2.3926 -1.4556
0.7961 -0.7394 -0.3788 0.6167 -0.4149 2.2609 0.0832 0.4752 -
0.1175 1.7551 ...

```

---



```

-2.4125
-6.5854];
net1.LW{2,1}=[...
 3.5553 -0.8929 0.5325 2.9584 3.4766 3.0452 1.7606 3.7334
0.1555 0.1280 ...
 3.0337 -0.1191 2.5053 3.5656 3.7327 -1.1664];
net1.b{2,1}=[...
 0.6312];
%-----
[net1,tr]=train(net1,nnInp,nnOut);
ke=tr.epoch(end)
E=tr.perf(end)
%melihat bobot input, lapisan dan bias
Weigh_Input=net1.IW{1,1}
Weigh_Bias_Input=net1.b{1,1}
Weigh_Layer=net1.LW{2,1}
Weigh_Bias_Layer=net1.b{2,1}
%Proses Genetic Evolutionary Algorithms-----
v=Weigh_Input';
b1=Weigh_Bias_Input';
w=Weigh_Layer';
b2=Weigh_Bias_Layer';
nnInput=nnInp';
nnOutput=nnOut';
global nnInput nnOutput;
[min,max]=CariMinMaxMatrix(v);
bWih.min=min-0.75;
bWih.max=max+0.75;
[min,max]=CariMinMaxMatrix(b1);
bBih.min=min-0.75;
bBih.max=max+0.75;
[min,max]=CariMinMaxMatrix(w);
bWho.min=min-0.75;
bWho.max=max+0.75;
[min,max]=CariMinMaxMatrix(b2);
bBho.min=min-0.75;
bBho.max=max+0.75;
MaxGen=1;
PopSize=10;
Beta=0.3;
x=v(:,1);
Ninput=length(x);
x=v(1,:);
Nhidden=length(x);
x=w(1,:);
Noutput=length(x);
[aMin,aAvg,aMax,BestChrom]=Genetic(MaxGen,PopSize,Beta,Ninput,...
Nhidden,Noutput,bWih,bBih,bWho,bBho,v,b1,w,b2);

```

---



```

BestChrom.Wih=v;
BestChrom.Bih=b1;
BestChrom.Who=w;
BestChrom.Bho=b2;
a=SimNet(nnInput,v,b1,w,b2);
%-----
%a=sim(net1,nnInp);
%a=a';
%-----
a=NNToNilai(a,Loadmin,Loadmax);
ta=zeros(rowT,1);
for i=1:rowT
    ta(i)=i;
end
target=train(:,25);
plot(ta,target,'b-',ta,a,'r-');
xlabel('input');
ylabel('Target dan Output');
legend('target','training');
grid;
cek=ddepoke(interface,'r3c27:r2114c27',a);
%Ramal
%a=sim(net1,nnRamal);
%a=a';
%a=NNToNilai(a,Loadmin,Loadmax);
%cek=ddepokc(interface,'r26c34:r27c34',a);

```

---

Untitled

TRAINGDM, Epoch 630350/800000, MSE 0.0010009/0.001, Gradient  
 1.24442e-005/1e-010  
 TRAINGDM, Epoch 630375/800000, MSE 0.0010009/0.001, Gradient  
 1.24437e-005/1e-010  
 TRAINGDM, Epoch 630400/800000, MSE 0.0010009/0.001, Gradient  
 1.24432e-005/1e-010  
 TRAINGDM, Epoch 630425/800000, MSE 0.00100089/0.001, Gradient  
 1.24426e-005/1e-010  
 TRAINGDM, Epoch 630450/800000, MSE 0.00100089/0.001, Gradient  
 1.24421e-005/1e-010  
 TRAINGDM, Epoch 630475/800000, MSE 0.00100089/0.001, Gradient  
 1.24415e-005/1e-010  
 TRAINGDM, Epoch 630500/800000, MSE 0.00100088/0.001, Gradient  
 1.2441e-005/1e-010  
 TRAINGDM, Epoch 630525/800000, MSE 0.00100088/0.001, Gradient  
 1.24404e-005/1e-010  
 TRAINGDM, Epoch 630550/800000, MSE 0.00100087/0.001, Gradient  
 1.24399e-005/1e-010  
 TRAINGDM, Epoch 630575/800000, MSE 0.00100087/0.001, Gradient  
 1.24393e-005/1e-010  
 TRAINGDM, Epoch 630600/800000, MSE 0.00100087/0.001, Gradient  
 1.24388e-005/1e-010  
 TRAINGDM, Epoch 630625/800000, MSE 0.00100086/0.001, Gradient  
 1.24383e-005/1e-010  
 TRAINGDM, Epoch 630650/800000, MSE 0.00100086/0.001, Gradient  
 1.24377e-005/1e-010  
 TRAINGDM, Epoch 630675/800000, MSE 0.00100086/0.001, Gradient  
 1.24372e-005/1e-010  
 TRAINGDM, Epoch 630700/800000, MSE 0.00100085/0.001, Gradient  
 1.24366e-005/1e-010  
 TRAINGDM, Epoch 630725/800000, MSE 0.00100085/0.001, Gradient  
 1.24361e-005/1e-010  
 TRAINGDM, Epoch 630750/800000, MSE 0.00100085/0.001, Gradient  
 1.24355e-005/1e-010  
 TRAINGDM, Epoch 630775/800000, MSE 0.00100084/0.001, Gradient  
 1.2435e-005/1e-010  
 TRAINGDM, Epoch 630800/800000, MSE 0.00100084/0.001, Gradient  
 1.24344e-005/1e-010  
 TRAINGDM, Epoch 630825/800000, MSE 0.00100083/0.001, Gradient  
 1.24339e-005/1e-010  
 TRAINGDM, Epoch 630850/800000, MSE 0.00100083/0.001, Gradient  
 1.24334e-005/1e-010  
 TRAINGDM, Epoch 630875/800000, MSE 0.00100083/0.001, Gradient  
 1.24328e-005/1e-010  
 TRAINGDM, Epoch 630900/800000, MSE 0.00100082/0.001, Gradient  
 1.24323e-005/1e-010  
 TRAINGDM, Epoch 630925/800000, MSE 0.00100082/0.001, Gradient  
 1.24317e-005/1e-010  
 TRAINGDM, Epoch 630950/800000, MSE 0.00100082/0.001, Gradient  
 1.24312e-005/1e-010  
 TRAINGDM, Epoch 630975/800000, MSE 0.00100081/0.001, Gradient  
 1.24306e-005/1e-010  
 TRAINGDM, Epoch 631000/800000, MSE 0.00100081/0.001, Gradient  
 1.24301e-005/1e-010  
 TRAINGDM, Epoch 631025/800000, MSE 0.0010008/0.001, Gradient  
 1.24295e-005/1e-010  
 TRAINGDM, Epoch 631050/800000, MSE 0.0010008/0.001, Gradient  
 1.2429e-005/1e-010  
 TRAINGDM, Epoch 631075/800000, MSE 0.0010008/0.001, Gradient  
 1.24284e-005/1e-010  
 TRAINGDM, Epoch 631100/800000, MSE 0.00100079/0.001, Gradient  
 1.24279e-005/1e-010  
 TRAINGDM, Epoch 631125/800000, MSE 0.00100079/0.001, Gradient  
 1.24274e-005/1e-010  
 TRAINGDM, Epoch 631150/800000, MSE 0.00100079/0.001, Gradient

Untitled

1.24268e-005/1e-010  
 TRAININGDM, Epoch 631175/800000, MSE 0.00100078/0.001, Gradient  
 1.24263e-005/1e-010  
 TRAININGDM, Epoch 631200/800000, MSE 0.00100078/0.001, Gradient  
 1.24257e-005/1e-010  
 TRAININGDM, Epoch 631225/800000, MSE 0.00100078/0.001, Gradient  
 1.24252e-005/1e-010  
 TRAININGDM, Epoch 631250/800000, MSE 0.00100077/0.001, Gradient  
 1.24246e-005/1e-010  
 TRAININGDM, Epoch 631275/800000, MSE 0.00100077/0.001, Gradient  
 1.24241e-005/1e-010  
 TRAININGDM, Epoch 631300/800000, MSE 0.00100076/0.001, Gradient  
 1.24235e-005/1e-010  
 TRAININGDM, Epoch 631325/800000, MSE 0.00100076/0.001, Gradient  
 1.2423e-005/1e-010  
 TRAININGDM, Epoch 631350/800000, MSE 0.00100076/0.001, Gradient  
 1.24224e-005/1e-010  
 TRAININGDM, Epoch 631375/800000, MSE 0.00100075/0.001, Gradient  
 1.24219e-005/1e-010  
 TRAININGDM, Epoch 631400/800000, MSE 0.00100075/0.001, Gradient  
 1.24214e-005/1e-010  
 TRAININGDM, Epoch 631425/800000, MSE 0.00100075/0.001, Gradient  
 1.24208e-005/1e-010  
 TRAININGDM, Epoch 631450/800000, MSE 0.00100074/0.001, Gradient  
 1.24203e-005/1e-010  
 TRAININGDM, Epoch 631475/800000, MSE 0.00100074/0.001, Gradient  
 1.24197e-005/1e-010  
 TRAININGDM, Epoch 631500/800000, MSE 0.00100074/0.001, Gradient  
 1.24192e-005/1e-010  
 TRAININGDM, Epoch 631525/800000, MSE 0.00100073/0.001, Gradient  
 1.24186e-005/1e-010  
 TRAININGDM, Epoch 631550/800000, MSE 0.00100073/0.001, Gradient  
 1.24181e-005/1e-010  
 TRAININGDM, Epoch 631575/800000, MSE 0.00100072/0.001, Gradient  
 1.24175e-005/1e-010  
 TRAININGDM, Epoch 631600/800000, MSE 0.00100072/0.001, Gradient  
 1.2417e-005/1e-010  
 TRAININGDM, Epoch 631625/800000, MSE 0.00100072/0.001, Gradient  
 1.24164e-005/1e-010  
 TRAININGDM, Epoch 631650/800000, MSE 0.00100071/0.001, Gradient  
 1.24159e-005/1e-010  
 TRAININGDM, Epoch 631675/800000, MSE 0.00100071/0.001, Gradient  
 1.24154e-005/1e-010  
 TRAININGDM, Epoch 631700/800000, MSE 0.00100071/0.001, Gradient  
 1.24148e-005/1e-010  
 TRAININGDM, Epoch 631725/800000, MSE 0.0010007/0.001, Gradient  
 1.24143e-005/1e-010  
 TRAININGDM, Epoch 631750/800000, MSE 0.0010007/0.001, Gradient  
 1.24137e-005/1e-010  
 TRAININGDM, Epoch 631775/800000, MSE 0.0010007/0.001, Gradient  
 1.24132e-005/1e-010  
 TRAININGDM, Epoch 631800/800000, MSE 0.00100069/0.001, Gradient  
 1.24126e-005/1e-010  
 TRAININGDM, Epoch 631825/800000, MSE 0.00100069/0.001, Gradient  
 1.24121e-005/1e-010  
 TRAININGDM, Epoch 631850/800000, MSE 0.00100068/0.001, Gradient  
 1.24115e-005/1e-010  
 TRAININGDM, Epoch 631875/800000, MSE 0.00100068/0.001, Gradient  
 1.2411e-005/1e-010  
 TRAININGDM, Epoch 631900/800000, MSE 0.00100068/0.001, Gradient  
 1.24104e-005/1e-010  
 TRAININGDM, Epoch 631925/800000, MSE 0.00100067/0.001, Gradient  
 1.24099e-005/1e-010  
 TRAININGDM, Epoch 631950/800000, MSE 0.00100067/0.001, Gradient  
 1.24094e-005/1e-010

Untitled

TRAININGM, Epoch 631975/800000, MSE 0.00100067/0.001, Gradient  
 1.24088e-005/1e-010  
 TRAININGM, Epoch 632000/800000, MSE 0.00100066/0.001, Gradient  
 1.24083e-005/1e-010  
 TRAININGM, Epoch 632025/800000, MSE 0.00100066/0.001, Gradient  
 1.24077e-005/1e-010  
 TRAININGM, Epoch 632050/800000, MSE 0.00100065/0.001, Gradient  
 1.24072e-005/1e-010  
 TRAININGM, Epoch 632075/800000, MSE 0.00100065/0.001, Gradient  
 1.24066e-005/1e-010  
 TRAININGM, Epoch 632100/800000, MSE 0.00100065/0.001, Gradient  
 1.24061e-005/1e-010  
 TRAININGM, Epoch 632125/800000, MSE 0.00100064/0.001, Gradient  
 1.24055e-005/1e-010  
 TRAININGM, Epoch 632150/800000, MSE 0.00100064/0.001, Gradient  
 1.2405e-005/1e-010  
 TRAININGM, Epoch 632175/800000, MSE 0.00100064/0.001, Gradient  
 1.24044e-005/1e-010  
 TRAININGM, Epoch 632200/800000, MSE 0.00100063/0.001, Gradient  
 1.24039e-005/1e-010  
 TRAININGM, Epoch 632225/800000, MSE 0.00100063/0.001, Gradient  
 1.24033e-005/1e-010  
 TRAININGM, Epoch 632250/800000, MSE 0.00100063/0.001, Gradient  
 1.24028e-005/1e-010  
 TRAININGM, Epoch 632275/800000, MSE 0.00100062/0.001, Gradient  
 1.24022e-005/1e-010  
 TRAININGM, Epoch 632300/800000, MSE 0.00100062/0.001, Gradient  
 1.24017e-005/1e-010  
 TRAININGM, Epoch 632325/800000, MSE 0.00100061/0.001, Gradient  
 1.24012e-005/1e-010  
 TRAININGM, Epoch 632350/800000, MSE 0.00100061/0.001, Gradient  
 1.24006e-005/1e-010  
 TRAININGM, Epoch 632375/800000, MSE 0.00100061/0.001, Gradient  
 1.24001e-005/1e-010  
 TRAININGM, Epoch 632400/800000, MSE 0.0010006/0.001, Gradient  
 1.23995e-005/1e-010  
 TRAININGM, Epoch 632425/800000, MSE 0.0010006/0.001, Gradient  
 1.2399e-005/1e-010  
 TRAININGM, Epoch 632450/800000, MSE 0.0010006/0.001, Gradient  
 1.23984e-005/1e-010  
 TRAININGM, Epoch 632475/800000, MSE 0.00100059/0.001, Gradient  
 1.23979e-005/1e-010  
 TRAININGM, Epoch 632500/800000, MSE 0.00100059/0.001, Gradient  
 1.23973e-005/1e-010  
 TRAININGM, Epoch 632525/800000, MSE 0.00100059/0.001, Gradient  
 1.23968e-005/1e-010  
 TRAININGM, Epoch 632550/800000, MSE 0.00100058/0.001, Gradient  
 1.23962e-005/1e-010  
 TRAININGM, Epoch 632575/800000, MSE 0.00100058/0.001, Gradient  
 1.23957e-005/1e-010  
 TRAININGM, Epoch 632600/800000, MSE 0.00100057/0.001, Gradient  
 1.23951e-005/1e-010  
 TRAININGM, Epoch 632625/800000, MSE 0.00100057/0.001, Gradient  
 1.23946e-005/1e-010  
 TRAININGM, Epoch 632650/800000, MSE 0.00100057/0.001, Gradient  
 1.23941e-005/1e-010  
 TRAININGM, Epoch 632675/800000, MSE 0.00100056/0.001, Gradient  
 1.23935e-005/1e-010  
 TRAININGM, Epoch 632700/800000, MSE 0.00100056/0.001, Gradient  
 1.2393e-005/1e-010  
 TRAININGM, Epoch 632725/800000, MSE 0.00100056/0.001, Gradient  
 1.23924e-005/1e-010  
 TRAININGM, Epoch 632750/800000, MSE 0.00100055/0.001, Gradient  
 1.23919e-005/1e-010  
 TRAININGM, Epoch 632775/800000, MSE 0.00100055/0.001, Gradient

Untitled

1.23913e-005/1e-010  
 TRAININGDM, Epoch 632800/800000, MSE 0.00100055/0.001, Gradient  
 1.23908e-005/1e-010  
 TRAININGDM, Epoch 632825/800000, MSE 0.00100054/0.001, Gradient  
 1.23902e-005/1e-010  
 TRAININGDM, Epoch 632850/800000, MSE 0.00100054/0.001, Gradient  
 1.23897e-005/1e-010  
 TRAININGDM, Epoch 632875/800000, MSE 0.00100053/0.001, Gradient  
 1.23891e-005/1e-010  
 TRAININGDM, Epoch 632900/800000, MSE 0.00100053/0.001, Gradient  
 1.23886e-005/1e-010  
 TRAININGDM, Epoch 632925/800000, MSE 0.00100053/0.001, Gradient  
 1.2388e-005/1e-010  
 TRAININGDM, Epoch 632950/800000, MSE 0.00100052/0.001, Gradient  
 1.23875e-005/1e-010  
 TRAININGDM, Epoch 632975/800000, MSE 0.00100052/0.001, Gradient  
 1.23869e-005/1e-010  
 TRAININGDM, Epoch 633000/800000, MSE 0.00100052/0.001, Gradient  
 1.23864e-005/1e-010  
 TRAININGDM, Epoch 633025/800000, MSE 0.00100051/0.001, Gradient  
 1.23858e-005/1e-010  
 TRAININGDM, Epoch 633050/800000, MSE 0.00100051/0.001, Gradient  
 1.23853e-005/1e-010  
 TRAININGDM, Epoch 633075/800000, MSE 0.00100051/0.001, Gradient  
 1.23848e-005/1e-010  
 TRAININGDM, Epoch 633100/800000, MSE 0.0010005/0.001, Gradient  
 1.23842e-005/1e-010  
 TRAININGDM, Epoch 633125/800000, MSE 0.0010005/0.001, Gradient  
 1.23837e-005/1e-010  
 TRAININGDM, Epoch 633150/800000, MSE 0.00100049/0.001, Gradient  
 1.23831e-005/1e-010  
 TRAININGDM, Epoch 633175/800000, MSE 0.00100049/0.001, Gradient  
 1.23826e-005/1e-010  
 TRAININGDM, Epoch 633200/800000, MSE 0.00100049/0.001, Gradient  
 1.2382e-005/1e-010  
 TRAININGDM, Epoch 633225/800000, MSE 0.00100048/0.001, Gradient  
 1.23815e-005/1e-010  
 TRAININGDM, Epoch 633250/800000, MSE 0.00100048/0.001, Gradient  
 1.23809e-005/1e-010  
 TRAININGDM, Epoch 633275/800000, MSE 0.00100048/0.001, Gradient  
 1.23804e-005/1e-010  
 TRAININGDM, Epoch 633300/800000, MSE 0.00100047/0.001, Gradient  
 1.23798e-005/1e-010  
 TRAININGDM, Epoch 633325/800000, MSE 0.00100047/0.001, Gradient  
 1.23793e-005/1e-010  
 TRAININGDM, Epoch 633350/800000, MSE 0.00100047/0.001, Gradient  
 1.23787e-005/1e-010  
 TRAININGDM, Epoch 633375/800000, MSE 0.00100046/0.001, Gradient  
 1.23782e-005/1e-010  
 TRAININGDM, Epoch 633400/800000, MSE 0.00100046/0.001, Gradient  
 1.23776e-005/1e-010  
 TRAININGDM, Epoch 633425/800000, MSE 0.00100045/0.001, Gradient  
 1.23771e-005/1e-010  
 TRAININGDM, Epoch 633450/800000, MSE 0.00100045/0.001, Gradient  
 1.23765e-005/1e-010  
 TRAININGDM, Epoch 633475/800000, MSE 0.00100045/0.001, Gradient  
 1.2376e-005/1e-010  
 TRAININGDM, Epoch 633500/800000, MSE 0.00100044/0.001, Gradient  
 1.23755e-005/1e-010  
 TRAININGDM, Epoch 633525/800000, MSE 0.00100044/0.001, Gradient  
 1.23749e-005/1e-010  
 TRAININGDM, Epoch 633550/800000, MSE 0.00100044/0.001, Gradient  
 1.23744e-005/1e-010  
 TRAININGDM, Epoch 633575/800000, MSE 0.00100043/0.001, Gradient  
 1.23738e-005/1e-010

Untitled

TRAININGDM, Epoch 633600/800000, MSE 0.00100043/0.001, Gradient  
 1.23733e-005/1e-010  
 TRAININGDM, Epoch 633625/800000, MSE 0.00100043/0.001, Gradient  
 1.23727e-005/1e-010  
 TRAININGDM, Epoch 633650/800000, MSE 0.00100042/0.001, Gradient  
 1.23722e-005/1e-010  
 TRAININGDM, Epoch 633675/800000, MSE 0.00100042/0.001, Gradient  
 1.23716e-005/1e-010  
 TRAININGDM, Epoch 633700/800000, MSE 0.00100041/0.001, Gradient  
 1.23711e-005/1e-010  
 TRAININGDM, Epoch 633725/800000, MSE 0.00100041/0.001, Gradient  
 1.23705e-005/1e-010  
 TRAININGDM, Epoch 633750/800000, MSE 0.00100041/0.001, Gradient  
 1.237e-005/1e-010  
 TRAININGDM, Epoch 633775/800000, MSE 0.0010004/0.001, Gradient  
 1.23694e-005/1e-010  
 TRAININGDM, Epoch 633800/800000, MSE 0.0010004/0.001, Gradient  
 1.23689e-005/1e-010  
 TRAININGDM, Epoch 633825/800000, MSE 0.0010004/0.001, Gradient  
 1.23683e-005/1e-010  
 TRAININGDM, Epoch 633850/800000, MSE 0.00100039/0.001, Gradient  
 1.23678e-005/1e-010  
 TRAININGDM, Epoch 633875/800000, MSE 0.00100039/0.001, Gradient  
 1.23672e-005/1e-010  
 TRAININGDM, Epoch 633900/800000, MSE 0.00100039/0.001, Gradient  
 1.23667e-005/1e-010  
 TRAININGDM, Epoch 633925/800000, MSE 0.00100038/0.001, Gradient  
 1.23661e-005/1e-010  
 TRAININGDM, Epoch 633950/800000, MSE 0.00100038/0.001, Gradient  
 1.23656e-005/1e-010  
 TRAININGDM, Epoch 633975/800000, MSE 0.00100037/0.001, Gradient  
 1.2365e-005/1e-010  
 TRAININGDM, Epoch 634000/800000, MSE 0.00100037/0.001, Gradient  
 1.23645e-005/1e-010  
 TRAININGDM, Epoch 634025/800000, MSE 0.00100037/0.001, Gradient  
 1.2364e-005/1e-010  
 TRAININGDM, Epoch 634050/800000, MSE 0.00100036/0.001, Gradient  
 1.23634e-005/1e-010  
 TRAININGDM, Epoch 634075/800000, MSE 0.00100036/0.001, Gradient  
 1.23629e-005/1e-010  
 TRAININGDM, Epoch 634100/800000, MSE 0.00100036/0.001, Gradient  
 1.23623e-005/1e-010  
 TRAININGDM, Epoch 634125/800000, MSE 0.00100035/0.001, Gradient  
 1.23618e-005/1e-010  
 TRAININGDM, Epoch 634150/800000, MSE 0.00100035/0.001, Gradient  
 1.23612e-005/1e-010  
 TRAININGDM, Epoch 634175/800000, MSE 0.00100035/0.001, Gradient  
 1.23607e-005/1e-010  
 TRAININGDM, Epoch 634200/800000, MSE 0.00100034/0.001, Gradient  
 1.23601e-005/1e-010  
 TRAININGDM, Epoch 634225/800000, MSE 0.00100034/0.001, Gradient  
 1.23596e-005/1e-010  
 TRAININGDM, Epoch 634250/800000, MSE 0.00100033/0.001, Gradient  
 1.2359e-005/1e-010  
 TRAININGDM, Epoch 634275/800000, MSE 0.00100033/0.001, Gradient  
 1.23585e-005/1e-010  
 TRAININGDM, Epoch 634300/800000, MSE 0.00100033/0.001, Gradient  
 1.23579e-005/1e-010  
 TRAININGDM, Epoch 634325/800000, MSE 0.00100032/0.001, Gradient  
 1.23574e-005/1e-010  
 TRAININGDM, Epoch 634350/800000, MSE 0.00100032/0.001, Gradient  
 1.23568e-005/1e-010  
 TRAININGDM, Epoch 634375/800000, MSE 0.00100032/0.001, Gradient  
 1.23563e-005/1e-010  
 TRAININGDM, Epoch 634400/800000, MSE 0.00100031/0.001, Gradient

Untitled

1.23557e-005/1e-010  
 TRAININGDM, Epoch 634425/800000, MSE 0.00100031/0.001, Gradient  
 1.23552e-005/1e-010  
 TRAININGDM, Epoch 634450/800000, MSE 0.00100031/0.001, Gradient  
 1.23546e-005/1e-010  
 TRAININGDM, Epoch 634475/800000, MSE 0.0010003/0.001, Gradient  
 1.23541e-005/1e-010  
 TRAININGDM, Epoch 634500/800000, MSE 0.0010003/0.001, Gradient  
 1.23535e-005/1e-010  
 TRAININGDM, Epoch 634525/800000, MSE 0.00100029/0.001, Gradient  
 1.2353e-005/1e-010  
 TRAININGDM, Epoch 634550/800000, MSE 0.00100029/0.001, Gradient  
 1.23524e-005/1e-010  
 TRAININGDM, Epoch 634575/800000, MSE 0.00100029/0.001, Gradient  
 1.23519e-005/1e-010  
 TRAININGDM, Epoch 634600/800000, MSE 0.00100028/0.001, Gradient  
 1.23513e-005/1e-010  
 TRAININGDM, Epoch 634625/800000, MSE 0.00100028/0.001, Gradient  
 1.23508e-005/1e-010  
 TRAININGDM, Epoch 634650/800000, MSE 0.00100028/0.001, Gradient  
 1.23502e-005/1e-010  
 TRAININGDM, Epoch 634675/800000, MSE 0.00100027/0.001, Gradient  
 1.23497e-005/1e-010  
 TRAININGDM, Epoch 634700/800000, MSE 0.00100027/0.001, Gradient  
 1.23492e-005/1e-010  
 TRAININGDM, Epoch 634725/800000, MSE 0.00100027/0.001, Gradient  
 1.23486e-005/1e-010  
 TRAININGDM, Epoch 634750/800000, MSE 0.00100026/0.001, Gradient  
 1.23481e-005/1e-010  
 TRAININGDM, Epoch 634775/800000, MSE 0.00100026/0.001, Gradient  
 1.23475e-005/1e-010  
 TRAININGDM, Epoch 634800/800000, MSE 0.00100025/0.001, Gradient  
 1.2347e-005/1e-010  
 TRAININGDM, Epoch 634825/800000, MSE 0.00100025/0.001, Gradient  
 1.23464e-005/1e-010  
 TRAININGDM, Epoch 634850/800000, MSE 0.00100025/0.001, Gradient  
 1.23459e-005/1e-010  
 TRAININGDM, Epoch 634875/800000, MSE 0.00100024/0.001, Gradient  
 1.23453e-005/1e-010  
 TRAININGDM, Epoch 634900/800000, MSE 0.00100024/0.001, Gradient  
 1.23448e-005/1e-010  
 TRAININGDM, Epoch 634925/800000, MSE 0.00100024/0.001, Gradient  
 1.23442e-005/1e-010  
 TRAININGDM, Epoch 634950/800000, MSE 0.00100023/0.001, Gradient  
 1.23437e-005/1e-010  
 TRAININGDM, Epoch 634975/800000, MSE 0.00100023/0.001, Gradient  
 1.23431e-005/1e-010  
 TRAININGDM, Epoch 635000/800000, MSE 0.00100023/0.001, Gradient  
 1.23426e-005/1e-010  
 TRAININGDM, Epoch 635025/800000, MSE 0.00100022/0.001, Gradient  
 1.2342e-005/1e-010  
 TRAININGDM, Epoch 635050/800000, MSE 0.00100022/0.001, Gradient  
 1.23415e-005/1e-010  
 TRAININGDM, Epoch 635075/800000, MSE 0.00100021/0.001, Gradient  
 1.23409e-005/1e-010  
 TRAININGDM, Epoch 635100/800000, MSE 0.00100021/0.001, Gradient  
 1.23404e-005/1e-010  
 TRAININGDM, Epoch 635125/800000, MSE 0.00100021/0.001, Gradient  
 1.23398e-005/1e-010  
 TRAININGDM, Epoch 635150/800000, MSE 0.0010002/0.001, Gradient  
 1.23393e-005/1e-010  
 TRAININGDM, Epoch 635175/800000, MSE 0.0010002/0.001, Gradient  
 1.23387e-005/1e-010  
 TRAININGDM, Epoch 635200/800000, MSE 0.0010002/0.001, Gradient  
 1.23382e-005/1e-010

Untitled

TRAININGDM, Epoch 635225/800000, MSE 0.00100019/0.001, Gradient  
 1.23376e-005/1e-010  
 TRAININGDM, Epoch 635250/800000, MSE 0.00100019/0.001, Gradient  
 1.23371e-005/1e-010  
 TRAININGDM, Epoch 635275/800000, MSE 0.00100019/0.001, Gradient  
 1.23365e-005/1e-010  
 TRAININGDM, Epoch 635300/800000, MSE 0.00100018/0.001, Gradient  
 1.2336e-005/1e-010  
 TRAININGDM, Epoch 635325/800000, MSE 0.00100018/0.001, Gradient  
 1.23354e-005/1e-010  
 TRAININGDM, Epoch 635350/800000, MSE 0.00100018/0.001, Gradient  
 1.23349e-005/1e-010  
 TRAININGDM, Epoch 635375/800000, MSE 0.00100017/0.001, Gradient  
 1.23343e-005/1e-010  
 TRAININGDM, Epoch 635400/800000, MSE 0.00100017/0.001, Gradient  
 1.23338e-005/1e-010  
 TRAININGDM, Epoch 635425/800000, MSE 0.00100016/0.001, Gradient  
 1.23332e-005/1e-010  
 TRAININGDM, Epoch 635450/800000, MSE 0.00100016/0.001, Gradient  
 1.23327e-005/1e-010  
 TRAININGDM, Epoch 635475/800000, MSE 0.00100016/0.001, Gradient  
 1.23321e-005/1e-010  
 TRAININGDM, Epoch 635500/800000, MSE 0.00100015/0.001, Gradient  
 1.23316e-005/1e-010  
 TRAININGDM, Epoch 635525/800000, MSE 0.00100015/0.001, Gradient  
 1.2331e-005/1e-010  
 TRAININGDM, Epoch 635550/800000, MSE 0.00100015/0.001, Gradient  
 1.23305e-005/1e-010  
 TRAININGDM, Epoch 635575/800000, MSE 0.00100014/0.001, Gradient  
 1.23299e-005/1e-010  
 TRAININGDM, Epoch 635600/800000, MSE 0.00100014/0.001, Gradient  
 1.23294e-005/1e-010  
 TRAININGDM, Epoch 635625/800000, MSE 0.00100014/0.001, Gradient  
 1.23289e-005/1e-010  
 TRAININGDM, Epoch 635650/800000, MSE 0.00100013/0.001, Gradient  
 1.23283e-005/1e-010  
 TRAININGDM, Epoch 635675/800000, MSE 0.00100013/0.001, Gradient  
 1.23278e-005/1e-010  
 TRAININGDM, Epoch 635700/800000, MSE 0.00100012/0.001, Gradient  
 1.23272e-005/1e-010  
 TRAININGDM, Epoch 635725/800000, MSE 0.00100012/0.001, Gradient  
 1.23267e-005/1e-010  
 TRAININGDM, Epoch 635750/800000, MSE 0.00100012/0.001, Gradient  
 1.23261e-005/1e-010  
 TRAININGDM, Epoch 635775/800000, MSE 0.00100011/0.001, Gradient  
 1.23256e-005/1e-010  
 TRAININGDM, Epoch 635800/800000, MSE 0.00100011/0.001, Gradient  
 1.2325e-005/1e-010  
 TRAININGDM, Epoch 635825/800000, MSE 0.00100011/0.001, Gradient  
 1.23245e-005/1e-010  
 TRAININGDM, Epoch 635850/800000, MSE 0.0010001/0.001, Gradient  
 1.23239e-005/1e-010  
 TRAININGDM, Epoch 635875/800000, MSE 0.0010001/0.001, Gradient  
 1.23234e-005/1e-010  
 TRAININGDM, Epoch 635900/800000, MSE 0.0010001/0.001, Gradient  
 1.23228e-005/1e-010  
 TRAININGDM, Epoch 635925/800000, MSE 0.00100009/0.001, Gradient  
 1.23223e-005/1e-010  
 TRAININGDM, Epoch 635950/800000, MSE 0.00100009/0.001, Gradient  
 1.23217e-005/1e-010  
 TRAININGDM, Epoch 635975/800000, MSE 0.00100008/0.001, Gradient  
 1.23212e-005/1e-010  
 TRAININGDM, Epoch 636000/800000, MSE 0.00100008/0.001, Gradient  
 1.23206e-005/1e-010  
 TRAININGDM, Epoch 636025/800000, MSE 0.00100008/0.001, Gradient



Untitled

```

1.23201e-005/1e-010
TRAININGDM, Epoch 636050/800000, MSE 0.00100007/0.001, Gradient
1.23195e-005/1e-010
TRAININGDM, Epoch 636075/800000, MSE 0.00100007/0.001, Gradient
1.2319e-005/1e-010
TRAININGDM, Epoch 636100/800000, MSE 0.00100007/0.001, Gradient
1.23184e-005/1e-010
TRAININGDM, Epoch 636125/800000, MSE 0.00100006/0.001, Gradient
1.23179e-005/1e-010
TRAININGDM, Epoch 636150/800000, MSE 0.00100006/0.001, Gradient
1.23173e-005/1e-010
TRAININGDM, Epoch 636175/800000, MSE 0.00100006/0.001, Gradient
1.23168e-005/1e-010
TRAININGDM, Epoch 636200/800000, MSE 0.00100005/0.001, Gradient
1.23162e-005/1e-010
TRAININGDM, Epoch 636225/800000, MSE 0.00100005/0.001, Gradient
1.23157e-005/1e-010
TRAININGDM, Epoch 636250/800000, MSE 0.00100005/0.001, Gradient
1.23151e-005/1e-010
TRAININGDM, Epoch 636275/800000, MSE 0.00100004/0.001, Gradient
1.23146e-005/1e-010
TRAININGDM, Epoch 636300/800000, MSE 0.00100004/0.001, Gradient
1.2314e-005/1e-010
TRAININGDM, Epoch 636325/800000, MSE 0.00100003/0.001, Gradient
1.23135e-005/1e-010
TRAININGDM, Epoch 636350/800000, MSE 0.00100003/0.001, Gradient
1.23129e-005/1e-010
TRAININGDM, Epoch 636375/800000, MSE 0.00100003/0.001, Gradient
1.23124e-005/1e-010
TRAININGDM, Epoch 636400/800000, MSE 0.00100002/0.001, Gradient
1.23118e-005/1e-010
TRAININGDM, Epoch 636425/800000, MSE 0.00100002/0.001, Gradient
1.23113e-005/1e-010
TRAININGDM, Epoch 636450/800000, MSE 0.00100002/0.001, Gradient
1.23107e-005/1e-010
TRAININGDM, Epoch 636475/800000, MSE 0.00100001/0.001, Gradient
1.23102e-005/1e-010
TRAININGDM, Epoch 636500/800000, MSE 0.00100001/0.001, Gradient
1.23096e-005/1e-010
TRAININGDM, Epoch 636525/800000, MSE 0.00100001/0.001, Gradient
1.23091e-005/1e-010
TRAININGDM, Epoch 636550/800000, MSE 0.001/0.001, Gradient
1.23085e-005/1e-010
TRAININGDM, Epoch 636564/800000, MSE 0.001/0.001, Gradient
1.23082e-005/1e-010
TRAININGDM, Performance goal met.

```

ke =

636564

E =

1.0000e-003

Weigh\_Input =

Columns 1 through 7

-1.6887	0.8024	0.1151	-1.8392	-1.9961	1.0824	
-0.2861						
1.0340	-0.5064	0.8570	-0.1427	-0.3235	-0.3476	

untitled

-0.1514						
4.5923	2.6143	1.6375	0.7031	-1.7330	1.7007	
-2.2181						
-1.7022	0.7019	-2.9933	0.9521	-1.4324	-2.6766	
-3.0649						
-2.7350	-2.4856	-0.6219	-1.9625	-2.8614	-2.8791	
-1.8929						
-1.4142	-1.6691	0.7025	-2.4289	-2.6843	-2.4614	
0.8221						
2.3762	2.1646	1.7833	2.3894	-2.5037	-0.3160	
0.1571						
-3.0975	-0.0408	-2.1642	-2.5573	-0.6421	-2.7807	
-2.9254						
0.3006	-0.1873	0.4318	1.5522	-2.3535	-1.6880	
0.9210						
0.8760	-0.6466	-0.3041	0.6778	-0.3655	2.3099	
0.1459						
-1.9509	-1.1061	1.3822	0.9450	-2.7777	-2.3081	
-0.5484						
0.8444	-1.4232	0.2780	-1.2591	0.7358	0.2627	
-1.0083						
-0.0793	-1.2429	-2.1982	-1.1600	-1.5097	-1.8821	
0.5844						
0.2657	-1.7921	-1.3430	-3.1980	0.5809	-0.1622	
-2.2081						
1.0320	-1.9319	-2.4889	0.4668	-3.0327	0.9390	
0.0658						
0.0598	3.8344	2.3010	1.0171	-0.3088	0.5412	
0.5052						

columns 8 through 14

-2.4778	0.9843	-2.0096	1.7431	-0.4023	-0.8363	
-0.1603						
0.2992	0.1425	-0.2009	0.1523	-0.6022	0.0077	
0.8920						
1.7780	-1.9535	0.4407	0.4307	0.9186	-0.7973	
-0.5381						
-0.1069	-2.8430	-1.0194	-1.4103	-2.6045	-2.2840	
0.5067						
-2.3236	-3.1457	0.7079	-2.5223	-1.3304	0.5491	
-0.7410						
-0.1587	-2.4356	0.9103	-3.4981	-1.3362	-2.9164	
-2.3277						
-0.7147	-0.6405	0.3396	-2.2347	-0.8999	-0.4325	
2.5750						
-0.6197	-1.0937	-2.7446	0.3695	-0.4298	0.5625	
-0.5049						
-0.0266	0.3331	0.8180	-1.4400	1.4911	1.4630	
-1.8910						
0.5281	-0.0580	1.8105	-0.7083	-2.2702	-1.4866	
0.5073						
0.0391	-0.8245	-2.6247	1.2239	-2.8563	-1.1979	
-0.0374						
0.7788	-2.5291	-1.9447	-1.8774	0.6005	-0.1786	
-2.4453						
-3.0884	-2.2889	0.2645	0.7128	1.2009	-2.5435	
-3.1004						
-1.9434	-1.5930	0.1285	-0.1958	-3.3884	-2.8078	
-2.1467						
0.1945	-2.0049	-0.3797	0.6616	0.5693	-0.8929	
-2.6947						
-1.7555	0.6866	0.4287	-0.9754	-2.3643	1.7877	
-1.1582						

Untitled

Columns 15 through 21

-1.2740	0.9487	0.2611	-0.2734	2.3908	-1.0889
-0.8561					
-0.0541	-0.5260	1.0476	-1.0629	0.3159	0.4333
0.1209					
-1.3734	1.7707	0.5143	-0.3428	0.1756	1.9781
-2.4892					
-0.0687	0.1972	-2.9217	-2.8659	-1.9972	-3.0347
-3.1443					
-1.0761	-2.6823	-2.6696	-1.0874	0.6433	-2.3914
-3.6022					
-2.1673	0.8407	-1.5946	-0.2805	-1.3377	0.6759
-0.9367					
-0.2247	-0.9851	1.3751	-2.8445	-0.5053	1.3442
-0.0907					
-3.1477	-0.4159	-2.9615	0.6031	-0.4598	-3.3971
-1.2751					
1.2788	0.2443	1.5454	1.0813	0.3696	-0.1416
-2.0801					
1.5770	1.0602	-2.4728	0.8275	0.2974	-0.7231
1.4553					
-2.1315	-1.4921	-1.4476	-1.0619	0.2277	1.4832
-0.1551					
0.2046	-0.4461	-1.6719	-2.4580	-0.0328	-0.7186
-1.6760					
-2.4702	-1.0258	-2.5273	0.5249	-0.1165	-3.4948
0.7407					
-0.4798	-0.4707	0.9549	-2.9043	-1.1640	-1.4641
0.1284					
-1.7613	-2.4407	-1.7984	-1.3271	-0.5935	1.2125
0.8276					
1.9653	-1.0115	-0.0751	-3.0362	3.3334	1.6776
0.1309					

Columns 22 through 24

-1.8377	0.8351	1.0724
-1.2924	3.6988	-8.0843
-0.5920	2.8322	0.5042
-0.7390	-0.3640	-0.7381
0.1624	0.3280	-0.3201
0.6002	-1.4507	-2.2649
1.6948	-1.6908	-5.1333
0.4398	-2.6117	-1.4098
-0.5689	-2.3827	-1.4517
-2.2529	-2.1220	0.8409
-0.3873	-3.1088	1.6626
1.8258	-1.8781	-2.2552
-0.3074	-1.3702	-0.7480
1.2001	0.3651	-3.3710
0.1652	-2.2063	-2.7302
-0.0083	-1.4573	-2.9372

weigh\_Bias\_Input =

-7.5556
1.0862
-7.7164
6.0713
3.8755
0.9101
-1.5067
2.7316

Untitled

```
-6.3700  
-5.7921  
-3.7292  
7.4605  
1.0932  
0.3563  
-2.4373  
-6.5011
```

```
Weigh_Layer =
```

```
Columns 1 through 7
```

```
3.5439 -0.7719 0.3204 2.9824 3.4143 3.0133  
0.7457
```

```
Columns 8 through 14
```

```
3.6727 0.1760 -0.4032 3.0247 -0.1040 2.4629  
3.5381
```

```
Columns 15 through 16
```

```
3.7260 -1.5209
```

```
Weigh_Bias_Layer =
```

```
0.6602
```

```
warning: The value of local variables may have been changed to  
match the
```

```
globals. Future versions of MATLAB will require that you  
declare
```

```
a variable to be global before you use that variable.  
> In F:\Tugas-Tugas\Zainul\ANNBio\DataTA.m at line 136
```

```
warning: The value of local variables may have been changed to  
match the
```

```
globals. Future versions of MATLAB will require that you  
declare
```

```
a variable to be global before you use that variable.  
> In F:\Tugas-Tugas\Zainul\ANNBio\DataTA.m at line 136
```


```
1
```

```
>>
```

TABEL  
DATA BEBAN G.I SENGKALING MALANG

Jam	1-Nov RABU MW	2-Nov KAMIS MW	3-Nov JUMAT MW	4-Nov SABTU MW	5-Nov MINGGU MW	6-Nov SENEN MW	7-Nov SELASA MW	8-Nov RABU MW	9-Nov KAMIS MW	10-Nov JUMAT MW	11-Nov SABTU MW	12-Nov MINGGU MW	13-Nov SENEN MW	14-Nov SELASA MW	15-Nov RABU MW
0:00	37.600	40.100	40.200	36.700	40.500	38.000	38.750	38.700	39.000	39.300	42.800	41.900	38.800	37.900	40.600
1:00	36.300	35.450	38.500	38.600	40.500	36.750	36.700	37.750	37.850	38.800	39.950	39.500	36.150	36.800	38.700
2:00	35.000	32.800	36.800	40.500	40.500	35.500	34.700	36.800	36.700	38.900	37.100	37.100	33.500	36.600	38.000
3:00	34.850	34.750	38.150	38.750	41.250	36.200	35.400	37.300	36.800	38.700	37.450	35.900	33.350	37.350	38.000
4:00	34.700	36.700	39.500	37.000	42.000	36.900	36.100	37.800	36.900	38.800	37.800	34.700	33.200	38.100	38.400
5:00	33.900	36.300	37.550	33.650	37.750	36.050	35.450	36.950	36.150	37.100	36.600	34.450	34.650	37.200	39.600
6:00	33.100	35.900	35.200	34.700	33.500	35.200	34.800	36.100	35.400	35.400	35.400	34.200	36.100	36.300	37.000
7:00	41.300	35.600	34.950	34.250	33.150	36.000	37.350	36.500	36.100	37.250	35.650	34.250	36.600	37.700	39.300
8:00	49.500	35.300	34.700	34.200	32.800	36.800	39.900	36.900	36.800	38.700	35.900	34.300	37.100	39.100	42.300
9:00	44.000	35.200	36.500	35.300	33.150	39.200	40.300	38.450	38.450	40.250	36.450	34.950	38.900	39.650	44.200
10:00	38.500	35.100	38.300	36.400	33.500	41.600	40.700	40.400	40.100	41.800	37.000	35.600	40.700	40.200	44.400
11:00	38.300	34.050	37.200	37.250	33.350	40.850	40.200	39.850	40.400	39.550	37.850	35.450	40.250	40.000	46.400
12:00	38.100	33.000	36.100	38.100	33.200	40.100	39.700	39.300	40.700	37.300	38.700	35.300	39.900	39.800	44.400
13:00	38.200	35.700	35.750	36.550	31.800	40.400	40.650	39.700	41.000	36.950	38.800	34.750	40.550	40.200	45.800
14:00	38.300	38.400	35.400	35.000	30.400	40.700	41.600	40.100	41.300	36.600	38.900	34.200	41.300	40.600	46.300
15:00	38.500	39.750	37.450	35.500	32.050	40.750	38.100	40.750	41.250	39.150	39.000	34.750	41.400	40.400	48.500
16:00	38.700	41.100	39.500	36.000	33.700	40.800	34.600	41.400	41.200	41.700	39.100	33.300	41.500	40.200	47.400
17:00	44.900	43.300	45.100	41.300	39.300	51.200	46.800	45.000	42.600	43.700	41.400	36.200	51.800	49.000	48.500
18:00	58.300	59.500	59.400	58.200	57.100	56.800	60.800	60.200	61.800	60.700	56.600	57.500	61.400	62.200	61.700
19:00	58.900	60.200	59.500	59.000	56.900	58.800	59.700	60.700	61.900	61.700	59.500	58.200	62.100	62.400	63.000
20:00	58.100	58.700	58.100	59.100	58.300	57.500	57.700	58.700	60.400	59.700	59.600	56.600	60.600	60.500	62.100
21:00	56.500	54.500	55.800	56.800	52.500	52.600	52.900	55.400	56.600	56.000	56.600	52.300	57.600	56.000	56.700
22:00	47.000	47.900	45.600	47.800	46.500	47.400	47.300	48.300	46.700	47.700	49.500	45.500	50.100	48.300	49.100
23:00	43.550	44.050	41.150	44.150	42.250	43.050	43.000	43.650	42.850	45.250	45.700	41.150	43.550	44.450	24.550

Jam	16-Nov KAMIS MW	17-Nov JUMAT MW	18-Nov SABTU MW	19-Nov MINGGU MW	20-Nov SENEN MW	21-Nov SELASA MW	22-Nov RABU MW	23-Nov KAMIS MW	24-Nov JUMAT MW	25-Nov SABTU MW	26-Nov MINGGU MW	27-Nov SENEN MW	28-Nov SELASA MW	29-Nov RABU MW	30-Nov KAMIS MW
0:00	39.200	42.750	42.600	40.000	39.400	43.000	42.300	42.500	47.900	40.300	43.300	43.000	42.500	42.500	41.900
1:00	39.100	42.050	41.500	38.500	38.250	40.850	40.000	40.200	42.800	38.700	39.750	39.500	40.100	40.100	41.600
2:00	39.000	41.400	41.000	37.000	37.100	38.700	37.700	37.900	37.700	37.100	37.200	36.000	37.700	37.700	41.300
3:00	39.700	41.850	40.250	36.400	37.200	39.400	40.150	39.950	37.950	37.200	37.400	36.400	36.750	37.700	41.100
4:00	40.400	42.300	39.300	35.800	37.300	40.100	42.600	42.000	38.200	37.300	37.600	36.800	35.800	37.700	41.900
5:00	38.800	40.350	37.600	35.150	37.050	39.250	39.350	36.700	37.100	37.650	36.050	36.700	35.300	38.000	39.050
6:00	37.200	38.400	35.700	34.500	36.800	38.400	36.100	35.400	36.000	38.000	34.500	36.600	34.800	38.300	37.200
7:00	38.350	36.800	35.600	34.250	37.250	39.200	37.500	32.050	31.600	39.750	34.400	37.050	37.250	39.300	33.950
8:00	39.500	35.200	35.500	34.000	37.700	40.000	38.900	28.700	27.200	41.500	34.300	37.500	39.700	40.300	30.700
9:00	41.200	33.200	37.100	33.950	39.700	43.100	38.800	27.700	27.650	42.650	35.850	40.050	39.950	41.200	31.900
10:00	42.900	31.200	38.700	33.900	41.700	46.200	38.700	26.700	28.100	43.800	37.400	42.600	40.200	42.100	33.100
11:00	42.750	30.700	38.450	34.200	41.000	45.150	38.500	26.450	34.700	41.600	37.150	40.950	39.700	41.800	31.250
12:00	42.600	30.200	38.200	34.500	40.300	44.100	38.300	26.200	41.300	39.400	36.900	39.300	39.200	41.500	29.400
13:00	41.150	31.150	37.550	34.350	41.100	44.300	39.250	26.650	41.650	41.300	34.150	41.200	39.650	41.950	31.100
14:00	39.700	32.100	36.900	34.200	41.900	44.500	40.200	27.100	42.000	43.200	31.400	43.100	40.100	42.400	32.800
15:00	43.700	37.000	37.550	33.650	42.500	44.850	38.900	35.800	42.350	41.550	32.550	42.250	42.900	42.450	37.450
16:00	47.700	41.900	38.200	37.100	43.100	45.200	37.600	44.500	42.700	39.900	33.700	43.400	45.700	42.500	42.100
17:00	47.200	43.500	42.900	41.800	47.900	46.500	45.500	36.000	46.400	42.400	42.400	47.200	49.700	45.300	44.600
18:00	61.100	62.300	61.400	58.400	64.200	63.400	59.300	50.100	58.800	60.200	59.000	62.400	63.500	61.700	62.800
19:00	62.300	64.000	61.300	59.000	63.200	63.900	59.800	55.100	58.900	60.500	59.300	62.500	63.200	62.000	63.600
20:00	61.100	61.100	59.200	58.500	62.000	61.200	58.300	55.300	58.000	57.800	58.200	59.600	62.100	60.900	61.400
21:00	56.600	58.200	56.400	55.300	58.800	58.300	57.400	53.700	52.100	56.200	54.600	50.400	57.600	57.700	57.800
22:00	49.600	50.400	49.300	48.600	50.800	51.300	51.200	34.000	48.700	47.300	45.000	48.000	50.400	50.100	49.800
23:00	46.150	46.200	44.650	44.000	46.900	46.800	46.950	40.950	44.500	44.800	44.000	45.250	46.450	46.000	24.900



**SINGLE LINE DIAGRAM**  
**GT. SENGKALING 1 P**

Disetujui :  
**MANAGER UPT**

Diperiksa :  
**ASMAN OPHAR**

Digambar :  
**JU Prnt Meter & Gardiel**

UPT MAJANS

REGION JAWA TENGAH DASRI BAIT

PT. PLN (PERSERO) PB

11/11/20

11/11/20

11/11/20





# LAMPIRAN

## ii

- BERITA ACARA KOMPRE
  - SURAT SURVEY P3B
  - LEMBAR BIMBINGAN SKRIPSI
-





INSTITUT TEKNOLOGI NASIONAL MALANG  
FAKULTAS TEKNOLOGI INDUSTRI  
JURUSAN TEKNIK ELEKTRO S-1  
KONSENTRASI TEKNIK ENERGI LISTRIK

## BERITA ACARA UJIAN SKRIPSI FAKULTAS TEKNOLOGI INDUSTRI

1. Nama : ZAINUL EFFENDI
2. NIM : 01.12.108
3. Jurusan : Teknik Elektro S-1
4. Konsentrasi : Teknik Energi Listrik
5. Judul Skripsi : PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL *BIO-INSPIRED* DENGAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORITHM* DI GARDU INDUK SENGKALING MALANG

Dipertahankan dihadapan Majelis Penguji Skripsi Jenjang Strata Satu (S-1) pada :

Hari : Selasa  
Tanggal : 04 September 2007  
Dengan Nilai : 74,85 ( B+ ) *By*


### Panitia Ujian Skripsi

  
Ketua Majelis Penguji  
Ir. Mochtar Asroni, MSME  
NIP. P. 1018100036

Sekretaris Majelis Penguji  
  
Ir. F. Yudi Limpraptono, MT  
NIP. P. 4039500274

### Anggota Penguji

Penguji Pertama  
  
Ir. Widodo Puji M, MT  
NIP.P. 1028700171

Penguji Kedua  
  
Ir. Eko Nurcahyo  
NIP.P. 1028700172



**PT PLN (PERSERO)  
PENYALURAN DAN PUSAT PENGATUR BEBAN JAWA BALI  
REGION JAWA TIMUR & BALI**

Jalan Suningrat No. 45 Taman Sidoarjo 61257

Telepon : (031) 7882113, 7882114

Facsimile : (031) 7882578, 7881024

Website : www.pln-jawa-bali.co.id

Kotak Pos : 4119 SBS

E-mail : region4@pln-jawa-bali.co.id

Nomor : 273 / 330 / RJTB / 2006  
Surat Scr. No. : ITN-552/III.TA-2/2/06  
Lampiran : 1 (satu) lampiran.  
Perihal : Ijin Survey/ Pengambilan Data.

27 DEC 2006

**Kepada Yth.**

**INSTITUT TEKNOLOGI NASIONAL MALANG  
FAKULTAS TEKNOLOGI INDUSTRI  
DI  
MALANG**

Menunjuk surat Saudara nomor : ITN-552/III.TA-2/2/06 tanggal 14 Desember 2006 perihal : Survey / Permintaan Data, dengan ini diberitahukan bahwa kami tidak keberatan untuk memberikan ijin kepada Mahasiswa Saudara, bernama :

➤ **ZAINUL EFFENDI**

**NIM : 01.12.108**

Untuk melakukan Pengambilan data pada PT. PLN (Persero) P3B Region Jawa Timur dan Bali UPT Malang, dengan persyaratan sebagai berikut :

1. Mahasiswa tersebut diatas supaya mengisi dan menanda tangani Surat Pernyataan 1 (satu) lembar bermeterai Rp. 6.000,-
2. Mahasiswa yang bersangkutan agar mematuhi peraturan/ketentuan yang berlaku di PT. PLN (PERSERO) sehingga faktor-faktor kerahasiaan harus benar-benar diutamakan.
3. Semua biaya perjalanan, penginapan, makan dan lain sebagainya tidak menjadi tanggungan PT. PLN (Persero) P3B Region Jawa Timur dan Bali.
4. Buku Laporan Kerja Praktek Mahasiswa tersebut agar dikirimkan kepada PT. PLN (Persero) P3B Region Jawa Timur dan Bali 1 (satu) buah.
5. Untuk informasi lebih lanjut dapat menghubungi PT. PLN (Persero) P3B Region Jawa Timur dan Bali Cq. Bidang SDM & ADMINISTRASI.

Demikian harap maklum dan terima kasih atas perhatian saudara.



Tembusan Yth. :

1. M.SDMO PLN P3B.



## FORMULIR BIMBINGAN SKRIPSI

Nama : ZAINUL EFFENDI  
Nim : 01.12.108  
Masa Bimbingan : 04 DESEMBER 2006 s/d 04 JULI 2007  
Judul Skripsi : PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL BIO-INSPIRED DENGAN MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORKS DAN GENETIC EVOLUTIONARY ALGORITHM DI G.I SENGKALING MALANG

No	Tanggal	Uraian	Paraf Pembimbing
1.	BAB I	PENDAHULUAN	<i>ef</i>
2.	BAB II	PERKIRAAN BEBAN LISTRIK	<i>ef</i>
3.	BAB III	TEORI JARINGAN SARAF TIRUAN DAN GENETIC EVOLUTIONARY ALGORITHM SERTA MENGETAHUI MODEL DARI BIO-INSPIRASI	<i>ef</i>
4.	BAB IV	ANALISIS PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL BIO-INSPIRED MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORKS DAN GENETIC EVOLUTIONARY ALGORITHM	<i>ef</i>
5.	BAB V	KESIMPULAN	
6.			
7.			
8.			
9.			
10.			

Malang, \_\_\_\_\_, 2007  
Dosen Pembimbing,

  
**(Ir. H. CHOIRUL SALEH, MT)**  
NIP. P. 1010880190



### PERSETUJUAN PERBAIKAN SKRIPSI

Dari hasil ujian skripsi Jurusan Teknik Elektro jenjang strata satu (S-1) yang diselenggarakan pada :

Hari : Selasa  
Tanggal : 04 September 2007

Telah dilakukan perbaikan skripsi oleh :

1. Nama : ZAINUL EFFENDI
2. NIM : 01.12.108
3. Jurusan : Teknik Elektro
4. Konsentrasi : Teknik Energi Listrik
5. Judul Skripsi : PERKIRAAN BEBAN JANGKA PENDEK DENGAN MODEL BIO-INSPIRED DENGAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORKS* DAN *GENETIC EVOLUTIONARY ALGORITHM* DI GARDU INDUK SENGKALING MALANG

Perbaikan meliputi :

No	Materi Perbaikan	Ket
1	Variabel inputan untuk program apakah hanya cukup satu variabel saja	✓

Dosen Pembimbing

Ir. H. Choirul Saleh, MT  
NIP. P. 1010880190

Dosen Penguji

Ir. Widodo Puji M, MT  
NIP.P. 1028700171



PERKUMPULAN PENGELOLA PENDIDIKAN UMUM DAN TEKNOLOGI NASIONAL MALANG  
**INSTITUT TEKNOLOGI NASIONAL MALANG**

FAKULTAS TEKNOLOGI INDUSTRI  
FAKULTAS TEKNIK SIPIL DAN PERENCANAAN  
PROGRAM PASCASARJANA MAGISTER TEKNIK

PTN (PERSERO) MALANG  
PERSERIKATAN NIAGA MALANG

Kampus I : Jl. Bendungan Sigura-gura No. 2 Telp. (0341) 551431 (Hunting) Fax. (0341) 553015 Malang 65145  
Kampus II : Jl. Raya Karanglo, Km 2 Telp. (0341) 417636 Fax. (0341) 417634 Malang

Nomor : ITN-065/I.TA/2/07

Malang, 16 Feb. 2007

Lampiran : -  
Perihal :

**BIMBINGAN SKRIPSI**

Kepada : Yth. Sdr. **Ir. H. CHOIRUL SALEH, MT**  
Dosen Pembimbing  
Jurusan T. Elektro S-1  
di  
Malang

Dengan hormat

Sesuai dengan permohonan dan persetujuan dalam proposal skripsi untuk mahasiswa :

Nama : ZAINUL EFFENDI  
Nim : 0112108  
Fakultas : Teknologi Industri  
Jurusan : Teknik Elektro S-1  
Konsentrasi : T. Energi Listrik

Maka dengan ini pembimbing tersebut kami serahkan sepenuhnya kepada Saudara/I selama masa waktu 6 (enam) bulan, terhitung mulai tanggal :

04 Desember 2006 s/d 04 Juni 2007

Sebagai satu syarat untuk menempuh Ujian Sarjana Teknik,  
Jurusan Teknik Elektro S-1

Demikian atas perhatian serta kerjasamanya yang baik kami sampaikan terima kasih.



Ketua Jurusan  
Teknik Elektro S-1

*[Signature]*  
Ir. F. Yudi Limpraptono, MT  
NIP. Y. 1639500274

Tembusan Kepada Yth:

1. Mahasiswa Yang Bersangkutan
2. Arsip

Form S-4a



**LEMBAR PENGAJUAN JUDUL SKRIPSI  
JURUSAN TEKNIK ELEKTRO S-1**

Konsentrasi : Teknik Energi Listrik/ Teknkn Elektronika \*)

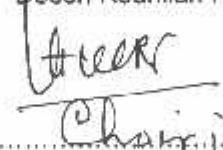

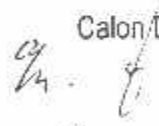
1	Nama Mahasiswa : <u>ZAITUL EFFENDI</u>	Nim : <u>09.12.100</u>
2	Waktu pengajuan	Tanggal : <u>11</u> Bulan : <u>8</u> Tahun : <u>06</u>
3	Spesifikasi judul ( berilah tanda silang )	
	<input checked="" type="checkbox"/> a. Sistem Tenaga Elektrik <input type="checkbox"/> b. Energi & Konversi Energi <input type="checkbox"/> c. Tegangan Tinggi & Pengukuran <input type="checkbox"/> d. Sistem Kendali Industri	<input type="checkbox"/> e. Elektronika & Komponen <input type="checkbox"/> f. Elektronika Digital & Komputer <input type="checkbox"/> g. Elektronika Komunikasi <input type="checkbox"/> h. lainnya .....
4	Konsultasikan judul sesuai materi bidang ilmu kepada Dosen *) : <u>Yrine Budi, ST, MT</u>	Mengetahui, Ketua Jurusan.  Ir. F. Yudi Limpraptono, MT Nip. Y. 1029500274
5	Judul yang diajukan mahasiswa :	<u>PERHARAAN BERBAGI JALURKA PERIDEK PERIGATI MODEL BIO-INSPIRED PERIGATI KATEGORIA KATI METODE ARTIFICIAL NEURAL NETWORK (ANN) DATA GENETIC EVOLUTIONARY ALGORITHM (GGA) Di G.D Blimbing Malang</u>
6	Perubahan Judul yang disetujui Dosen sesuai materi bidang ilmu	..... ..... .....
7	Catatan :	..... ..... .....
	Persetujuan Judul Skripsi yang dikonsultasikan kepada Dosen materi bidang ilmu	Disetujui, <u>22 Agustus, 2006</u> Dosen  <u>Yrine Budi S.</u>

**Perhatian :**

1. Formulir Pengajuan ini harap dikembalikan kepada jurusan paling lambat satu minggu setelah disetujui kelompok dosen keahlian dengan dilampirkan proposal skripsi beserta persyaratan skripsi sesuai form S-1
2. Keterangan : \*) coret yang tidak perlu  
\*\* dilingkari a, b, c, ..... atau g. sesuai bidang keahlian

## BERITA ACARA SEMINAR PROPOSAL SKRIPSI JURUSAN TEKNIK ELEKTRO S-1

Konsentrasi : Teknik Energi Listrik/Teknik Elektronika\*)

1.	Nama Mahasiswa: <u>ZAMUL EFFENDI</u>	Nim: <u>01.12.108</u>
2.	Keterangan	Tanggal
	Pelaksanaan	<u>01-12-2006</u>
Waktu		
Tempat		
Ruang:		
Spesifikasi Judul (berilah tanda silang**)		
3.	a. Sistem Tenaga Elektrik	e. Elektronika & Komponen
	b. Energi & Konversi Energi	f. Elektronika Digital & Komputer
	c. Tegangan Tinggi & Pengukuran	g. Elektronika Komunikasi
	d. Sistem Kendali Industri	h. lainnya .....
4.	Judul Proposal yang diseminarkan Mahasiswa	<u>PERKEMBANGAN BERBASIS LOGIKA FUZZY DENGAN MODEL BIO-INSPIRED DENGAN MELAKUKAKAN METODE ARTIFICIAL NEURAL NETWORK DARI GENETIC EVOLUTIONARY ALGORITHM DIGI BUMBUNG - MALANG</u>
5.	Perubahan Judul yang diusulkan oleh Kelompok Dosen Keahlian	..... ..... .....
6.	Catatan:	..... ..... .....
	Catatan:	..... ..... .....
Persetujuan Judul Skripsi		
7.	Disetujui, Dosen Keahlian I	Disetujui, Dosen Keahlian II
	 ..... Chairi.....	.....
	Mengetahui, Ketua Jurusan	Disetujui, Calon Dosen Pembimbing ybs
	 <u>Ir. F. Yudi Limpraptono, MT</u> NIP. P. 1039500274	 <u>Pr. Chairul Saleh, MT</u>

Perhatian:

1. Keterangan: \*) Coret yang tidak perlu
- \*\*) dilingkari a, b, c, ..... atau g sesuai bidang keahlian