

**A STUDY ON THE PERFORMANCE OF BACK PROPOGATION AND  
INDIVIDUAL FORECAST TECHNIQUE IN DEVELOPING REAL  
TIME FLOOD FORECASTING MODEL FOR JOHOR CATCHMENT  
AREA**

**(KAJIAN TERHADAP KEBOLEHUPAYAAN KAEDAH RAMBATAN  
KEBELAKANG DAN KAEDAH PERAMAL INDIVIDU DI DALAM  
MEMBANGUNKAN MODEL RAMALAN BANJIR MASA NYATA BAGI  
KAWASAN TADAHAN HUJAN NEGERI JOHOR)**

**KETUA PROJEK:**

NURULHUDA FIRDAUS BT MOHD AZMI

**PENYELIDIK:**

ROSELINA BT SALEHUDDIN

RAZANA BT ALWEE

MOHAMAD SHUKOR B TALIB

**PUSAT PENGURUSAN PENYELIDIKAN**

**UNIVERSITI TEKNOLOGI MALAYSIA**

## **PENGHARGAAN**

Dengan nama Allah Yang Maha Pemurah Lagi Maha Penyayang. Selawat serta salam ke atas junjungan besar Nabi Muhammad SAW dan ahli keluarga baginda serta sahabat-sahabat baginda. Semoga Allah mencucuri rahmat ke atas roh mereka. Segala puji dan kesyukuran kepada Allah SWT kerana dengan limpah kurnia dan keberkataan-Nya, laporan ini berjaya disiapkan.

Setingg-tinggi penghargaan ditujukan kepada Kementerian Sains, Teknologi Dan Inovasi di atas grant yang diperuntukkan bagi membolehkan kajian ini dilaksanakan.

Terima kasih diucapkan juga kepada Pusat Pengurusan Penyelidikan, Universiti Teknologi Malaysia di atas sokongan dan panduan di dalam mengurus grant penyelidikan. Kepada semua penyelidik iaitu Pn Roselina Bt Salehuddin, Pn Razana Bt Alwee dan En Mohamad Shukor B Talib, terima kasih di atas dorongan, perbincangan dan sokongan yang telah diberikan. Tidak dilupakan juga kepada En Abdul Hadi dan Cik Nuradibah Bt Edros di atas kegigihan dan kecekalan dalam menyiapkan kajian ini.

Akhir sekali penghargaan ini ditujukan kepada staf-staf di Jabatan Pemodelan dan Pengkomputeran Industri, Fakulti Sains Komputer dan Sistem Maklumat yang terlibat sama ada secara langsung atau tidak langsung di dalam membantu menyiapkan laporan projek ini.

Sekian.

## **ABSTRAK**

Meramalkan sesuatu perkara atau kejadian adalah penting. Ia dapat membantu kita untuk merancang atau membuat persediaan dalam menghadapi sebarang kemungkinan yang mungkin berlaku. Sebagai contoh, banjir kilat boleh berlaku disebabkan oleh berlakunya hujan yang sangat lebat. Oleh itu, ramalan hujan boleh membantu kita untuk membuat perancangan yang berkaitan dengan cuaca memandangkan banjir merupakan di antara bencana yang kerap berlaku dan menyebabkan kemusnahan alam yang boleh menyebabkan kehilangan sumber ekonomi. Kajian yang akan dijalankan ini merupakan analisa peramalan taburan hujan menggunakan pendekatan analisa statistik melalui kaedah Box Jenkins serta pendekatan Rangkaian Neural melalui kaedah Rambatan Kebelakang. Kedua-dua pendekatan ini akan di buat perbandingan bagi mendapatkan model peramalan yang terbaik serta boleh dipercayai. Model yang akan dibangunkan ini merupakan input bagi pangkalan data MHIS (Malaysian Hydrological Information System) dan dengan itu peramalan banjir terhadap masa nyata dapat dibangunkan.. Data bagi taburan hujan yang akan digunakan di dalam kajian ini diperolehi daripada Bahagian Hidrologi dan Sumber Air, Jabatan Pengairan dan Saliran negeri Johor. Proses pembangunan projek ini, akan dilakukan dengan menggunakan perisian MATLAB dan STATISTICA.

### **KATA KUNCI:**

Peramalan banjir , Data siri masa, Box Jenkins, Rangkaian neural, Rambatan kebelakang

## **ABSTRACT**

Predictions of event or incident are important. It can help people to plan or make a preparation to face any possibility that may happen. For example, flash floods may occur because of heavy rainfall. There for, rain prediction may help us to make a planning that connected with weather since floods are among the most frequent and costly natured disasters cause of economic loss. This project will develop a real-time flood forecasting model for Johor catchment areas as to provide early warning to flood disaster. The model will be developed based on the comparison of Neural Network and individual forecast approach. The approaches are used to obtain an accurate, trusted and optimal flood forecast model. This real-time flood forecasting will be new instantaneous data model available in the MHIS (Malaysian Hydrological Information System) database, it is now possible to model the flood forecasting in real-time.

### **KEYWORDS:**

Flood Forecasting, Time Series Data, Box Jenkins, Neural Networks, Back Propagation

## KANDUNGAN

<b>BAB</b>	<b>PERKARA</b>	<b>HALAMAN</b>
	<b>PENGHARGAAN</b>	i
	<b>ABSTRAK</b>	ii
	<b>ABSTRACT</b>	iii
	<b>KANDUNGAN</b>	iv
	<b>SENARAI LAMPIRAN</b>	
<b>1</b>	<b>Pengenalan</b>	
	1.1 Pendahuluan	1
	1.2 Matlamat	1
	1.3 Objektif	2
	1.4 Skop	2
<b>2</b>	<b>KAJIAN LATAR BELAKANG</b>	
	2.1 Stesen Taburan Hujan	4
	2.2 Alat Pengukuran Hujan	5
	2.2.1 Pengenalan	5
	2.2.2 Kawasan Pencerapan	6

<b>3</b>	<b>KAJIAN LITERATUR</b>	
	3.1 Pengenalan	9
	3.2 Taburan Hujan di Malaysia	10
	3.2.1 Perubahan Hujan Bermusim di Semenanjung Malaysia	10
	3.2.2 Perubahan Hujan Bermusim di Sabah dan Sarawak	11
	3.3 Sistem Pernomboran Stesen Penyukat Hujan	13
	3.4 Teknik Peramalan	14
	3.4.1 Pengenalan	14
	3.4.2 Peramalan Siri Masa	15
	3.5 Metodologi Peramalan Box-Jenkins	17
	3.5.1 Pengecaman	17
	3.5.2 Penganggaran	22
	3.5.3 Semakan Diagnosis	23
	3.5.4 Peramalan	24
	3.6 Metodologi Peramalan Rangkaian Neural	25
	3.6.1 Konsep Asas Senibina Rangkaian Neural	26
	3.6.2 Struktur Rangkaian	29
	3.6.3 Algoritma Pembelajaran	32
	3.6.4 Fungsi Penggiatan	33
	3.6.5 Senibina Rangkaian	36
	3.6.5.1 Faktor-Faktor yang Mempengaruhi Prestasi Rangkaian	39
	3.6.6 Pendekatan Kaedah Rambatan ke Belakang	40
	3.6.6.1 Proses Pembelajaran	42
	3.6.7 Langkah-Langkah Peramalan Menggunakan Kaedah Rangkaian Neural	44
<b>4</b>	<b>REKABENTUK MODEL PERAMALAN BOX-JENKINS</b>	
	4.1 Pengenalan	50
	4.2 Penentuan Model Peramalan Bagi Daerah Batu Pahat	52

4.3	Penentuan Model Peramalan Bagi Daerah Johor Bahru	59
4.4	Penentuan Model Peramalan Bagi Daerah Kluang	65
4.5	Penentuan Model Peramalan Bagi Daerah Kota Tinggi	71
4.6	Penentuan Model Peramalan Bagi Daerah Mersing	77
4.7	Penentuan Model Peramalan Bagi Daerah Muar	82
4.8	Penentuan Model Bagi Daerah Pontian	89
4.9	Penentuan Model Bagi Daerah Segamat	95
<b>5</b>	<b>REKABENTUK MODEL PERAMALAN RANGKAIAN NEURAL</b>	
5.1	Pengenalan	102
5.2	Penjelmaan Data	103
5.3	Pembahagian dan Penyusunan Data	105
5.4	Rekabentuk Model Rangkaian	106
	5.4.1 Arahan Merekabentuk Model Rangkaian dengan Menggunakan Perisian Matlab 6.1	107
	5.4.1.1 Model Rangkaian bagi Stesen Ldg. Segamat Daerah Segamat.	107
<b>6</b>	<b>ANALISA HASIL</b>	
6.1	Pengenalan	118
6.2	Analisa Hasil Peramalan Melalui Kaedah Box-Jenkins	118
	6.2.1 Daerah Batu Pahat	119
	6.2.2 Daerah Johor Bahru	120
	6.2.3 Daerah Kluang	121
	6.2.4 Daerah Kota Tinggi	122
	6.2.5 Daerah Mersing	123
	6.2.6 Daerah Muar	124
	6.2.7 Daerah Pontian	125
	6.2.8 Daerah Segamat	126

6.3 Analisa Hasil Peramalan Melalui Kaedah Rangkaian Neural	127
6.3.1 Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat	128
6.3.2 Stesen Ldg. Union Yong Peng Daerah Batu Pahat	132
6.3.3 Stesen Ldg. Senai Daerah Johor Bahru	136
6.3.4 Stesen Ldg. Sg. Tiram Daerah Johor Bahru	140
6.3.5 Stesen Ldg. Simpang Renggam Daerah Kluang	144
6.3.6 Stesen Ldg. Ulu Paloh Daerah Kluang	148
6.3.7 Stesen Ldg. Getah Malaya Daerah Kota Tinggi	152
6.3.8 Stesen Rancangan Ulu Sebol Daerah Kota Tinggi	156
6.3.9 Stesen Ibu Bekalan Kahang Daerah Mersing	160
6.3.10 Stesen Pusat Pertanian Endau Daerah Mersing	164
6.3.11 Stesen Ldg. Temiang Renchong Daerah Muar	168
6.3.12 Stesen Ldg. Gomali Batu Enam Daerah Muar	172
6.3.13 Stesen Ldg. Getah Kukup Daerah Pontian	176
6.3.14 Stesen Pintu Pasang Surut Senggarang Daerah Pontian	180
6.3.15 Stesen Ldg. Segamat Daerah Segamat	184
6.3.16 Stesen Ldg. Mados Sermin Segamat	188
6.4 Analisa Model Rangkaian Menggunakan Teknik Rangkaian Neural	192

## **7 KESIMPULAN**

7.1 Pengenalan	198
7.2 Masalah dan Cadangan	199
7.3 Kesimpulan	202

## **RUJUKAN**

### **LAMPIRAN A – AB4**



## SENARAI LAMPIRAN

### LAMPIRAN

### TAJUK

A	Senarai stesen taburan hujan
B	Alat pengukuran hujan
B1	Kawasan Pencerapan
B2	<i>Adang Stevenson</i>
B3	Termometer Kering dan Basah
B4	Termometer Maksima dan Termometer Minima
B5	Termograf
B6	Higrograf
B7	Penyukat Sejalan
B8	Tolok Cangkuk
B9	<i>Cups Anemometer</i>
B10	Tolok Hujan
B11	Perakam Hujan
B12	Perakam Penyinaran Matahari
B13	<i>Thedolite (Tracking Balloon)</i>
B14	Anemometer
C	Contoh sebahagian data taburan hujan yang diterima. Stesen: Pintu Pasang Surut Kampung Sungai Rengit Daerah Batu Pahat
D	Contoh sebahagian data disusun
E	Penentuan model peramalan bagi Daerah Batu Pahat
F	Penentuan model peramalan bagi Daerah Johor Bahru
G	Penentuan model peramalan bagi Daerah Kluang
H	Penentuan model peramalan bagi Daerah Kota Tinggi
I	Penentuan model peramalan bagi Daerah Mersing
J	Penentuan model peramalan bagi Daerah Muar
K	Penentuan model peramalan bagi Daerah Pontian
L	Penentuan model peramalan bagi Daerah Segamat

M	Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat
M1	Larian latihan model rangkaian
M2	Rajah pencapaian larian latihan
M3	Graf taburan hujan (validasi)
M4	Graf bandingan data sebenar dengan data ramalan
N	Stesen Ldg. Union Yong Peng Daerah Batu Pahat
N1	Larian latihan model rangkaian
N2	Rajah pencapaian larian latihan
N3	Graf taburan hujan (validasi)
N4	Graf bandingan data sebenar dengan data ramalan
O	Stesen Ldg. Senai Daerah Johor Bahru
O1	Larian latihan model rangkaian
O2	Rajah pencapaian larian latihan
O3	Graf taburan hujan (validasi)
O4	Graf bandingan data sebenar dengan data ramalan
P	Stesen Ldg. Sg. Tiram Daerah Johor Bahru.
P1	Larian latihan model rangkaian
P2	Rajah pencapaian larian latihan
P3	Graf taburan hujan (validasi)
P4	Graf bandingan data sebenar dengan data ramalan
Q	Stesen Ldg. Simpang Renggam Daerah Kluang
Q1	Larian latihan model rangkaian
Q2	Rajah pencapaian larian latihan
Q3	Graf taburan hujan (validasi)
Q4	Graf bandingan data sebenar dengan data ramalan
R	Stesen Ldg. Ulu Paloh Daerah Kluang
R1	Larian latihan model rangkaian
R2	Rajah pencapaian larian latihan
R3	Graf taburan hujan (validasi)
R4	Graf bandingan data sebenar dengan data ramalan
S	Stesen Ldg. Getah Malaya Daerah Kota Tinggi

S1	Larian latihan model rangkaian
S2	Rajah pencapaian larian latihan
S3	Graf taburan hujan (validasi)
S4	Graf bandingan data sebenar dengan data ramalan
T	Stesen Rancangan Ulu Sebol Daerah Kota Tinggi
T1	Larian latihan model rangkaian
T2	Rajah pencapaian larian latihan
T3	Graf taburan hujan (validasi)
T4	Graf bandingan data sebenar dengan data ramalan
U	Stesen Ibu Bekalan Kahang Daerah Mersing
U1	Larian latihan model rangkaian
U2	Rajah pencapaian larian latihan
U3	Graf taburan hujan (validasi)
U4	Graf bandingan data sebenar dengan data ramalan
V	Stesen Pusat Pertanian Endau Daerah Mersing
V1	Larian latihan model rangkaian
V2	Rajah pencapaian larian latihan
V3	Graf taburan hujan (validasi)
V4	Graf bandingan data sebenar dengan data ramalan
W	Stesen Ldg. Temiang Renchong Daerah Muar
W1	Larian latihan model rangkaian
W2	Rajah pencapaian larian latihan
W3	Graf taburan hujan (validasi)
W4	Graf bandingan data sebenar dengan data ramalan
X	Stesen Ldg. Gomali, Batu Enam Daerah Muar
X1	Larian latihan model rangkaian
X2	Rajah pencapaian larian latihan
X3	Graf taburan hujan (validasi)
X4	Graf bandingan data sebenar dengan data ramalan
Y	Stesen Ldg. Getah Kukup Daerah Pontian
Y1	Larian latihan model rangkaian

Y2	Rajah pencapaian larian latihan
Y3	Graf taburan hujan (validasi)
Y4	Graf bandingan data sebenar dengan data ramalan
Z	Stesen Pintu Pasang Surut Senggarang Daerah Pontian
Z1	Larian latihan model rangkaian
Z2	Rajah pencapaian larian latihan
Z3	Graf taburan hujan (validasi)
Z4	Graf bandingan data sebenar dengan data ramalan
AA	Stesen Ldg. Segamat Daerah Segamat
AA1	Larian latihan model rangkaian
AA2	Rajah pencapaian larian latihan
AA3	Graf taburan hujan (validasi)
AA4	Graf bandingan data sebenar dengan data ramalan
AB	Stesen Ldg. Mados Sermin Daerah Segamat
AB1	Larian latihan model rangkaian
AB2	Rajah pencapaian larian latihan
AB3	Graf taburan hujan (validasi)
AB4	Graf bandingan data sebenar dengan data ramalan

# **BAB 1**

## **PENGENALAN**

### **1.1 Pendahuluan**

Iklm Malaysia khususnya di negeri Johor mempunyai suhu yang seragam, kelembapan yang tinggi dan hujan yang banyak. Oleh itu, peramalan terhadap hujan dapat membantu pihak-pihak tertentu dalam meramalkan hujan untuk melakukan sesuatu tugas atau perancangan termasuklah persediaan dalam menghadapi kemungkinan yang akan berlaku. Selain itu peramalan hujan juga dapat membantu untuk mengenalpasti lokasi tertentu, kawasan atau daerah di sesebuah negeri yang menerima hujan yang paling kerap dalam setahun.

Kajian ini merupakan satu kajian untuk meramalkan taburan hujan mengikut stesen tertentu di setiap daerah di negeri Johor. Kajian yang dijalankan ini melibatkan data hujan dari stesen-stesen penyukat hujan yang dipilih.

### **1.2 Matlamat**

Matlamat utama projek analisa ini adalah untuk mengenalpasti ramalan taburan hujan di samping untuk membandingkan model hasil output ramalan hujan dengan

menggunakan kaedah Box-Jenkins dan kaedah rangkaian neural bagi mendapatkan model peramalan yang terbaik.

### **1.3 Objektif**

Objektif kajian ini adalah:

- i. Melakukan perbandingan bagi model-model output peramalan hujan menggunakan kaedah Box-Jenkins dan kaedah Rangkaian Neural untuk memperolehi model yang terbaik dan boleh dipercayai.
- ii. Meramalkan taburan hujan bagi jangka masa lima hari akan datang.
- iii. Menganalisa dan mengenalpasti kaedah yang digunakan untuk membangunkan model rangkaian taburan hujan sama ada dapat menghasilkan model peramalan taburan hujan yang baik atau sebaliknya.

### **1.4 Skop**

Skop yang akan dicapai bagi projek ini adalah:

- i. Membina dan membangunkan model peramalan menggunakan kaedah Box-Jenkins dan kaedah Rangkaian Neural.
- ii. Membuat peramalan hujan bagi 16 stesen yang dipilih mengikut kriteria tertentu di negeri Johor untuk tempoh lima hari akan datang. Kriteria

tersebut ialah data stesen yang mempunyai taburan hujan yang lengkap sahaja yang akan dipilih.

- iii. Menganalisa nilai peramalan yang diperolehi.
- iv. Mempelajari dan memahami kaedah Box-Jenkins dan kaedah Rangkaian Neural dalam membuat peramalan.
- v. Menggunakan perisian STATISTICA dan Matlab 6.1 untuk membangunkan model peramalan.

## **BAB 2**

### **KAJIAN LATAR BELAKANG**

#### **2.1 Stesen Taburan Hujan**

Stesen Hidrologi Semenanjung Malaysia menyediakan maklumat berkaitan hidrologi seperti stesen-stesen aras air, sejatan, telemetrik dan sebagainya. Dalam projek ini, data taburan hujan dari stesen telemetrik dipilih.

Data rekod hujan harian dalam unit milimeter diperolehi dari Bahagian Hidrologi dan Sumber Air, Jabatan Pengairan dan Saliran Johor (JPS). 16 buah stesen penyukat hujan di negeri Johor dipilih daripada stesen-stesen penyukat hujan telemetrik yang terdapat di seluruh negara. Senarai stesen taburan hujan yang dipilih disertakan dalam Lampiran A. Data taburan hujan diambil dari bulan Januari tahun 2000 sehingga bulan Julai tahun 2002. Data harian yang diambil adalah hasil terkumpul daripada bacaan pada setiap 6 jam.

Data taburan hujan yang diperolehi adalah sebanyak 15 088 nilai bacaan, iaitu sebanyak 943 hari bacaan data hujan. Manakala bilangan stesen pula ialah 16 buah stesen. Bagi setiap daerah, sebanyak 2 buah stesen penyukat hujan akan dipilih mengikut kriteria tertentu. Jadual 2.1 di bawah menunjukkan bilangan stesen yang dipilih mengikut daerah.



**Jadual 2:** Daerah bagi stesen-stesen taburan hujan di Negeri Johor

<b>DAERAH</b>	<b>BILANGAN STESEN</b>
Batu Pahat	2 buah stesen
Johor Bahru	2 buah stesen
Kluang	2 buah stesen
Kota Tinggi	2 buah stesen
Mersing	2 buah stesen
Muar	2 buah stesen
Pontian	2 buah stesen
Segamat	2 buah stesen
<b>JUMLAH</b>	<b>16 buah stesen</b>

## **2.2 Alat Pengukuran Hujan**

### **2.2.1 Pengenalan**

Alat pengukur hujan adalah satu cara yang paling mudah untuk menyukat jumlah hujan yang turun. Alat pengukur hujan boleh memberitahu kita jumlah hujan yang turun dalam satu hari. Sukatan hujan kebiasaannya akan diambil dalam unit milimeter (mm).

### 2.2.2 Kawasan Pencerapan

Kawasan pencerapan ialah kawasan yang digunakan untuk menempatkan peralatan untuk menyukat hujan. Peralatan-peralatan di bawah adalah peralatan yang biasanya terdapat di kawasan pencerapan. Lampiran B1 menggambarkan kawasan pencerapan hujan.

1) *Adang Stevenson*

*Adang Stevenson* merupakan suatu tempat yang digunakan untuk meletakkan alat-alat kaji cuaca untuk menolak hujan. Lampiran B2 menunjukkan gambaran bagi *Adang Stevenson*.

Alat-alat kaji cuaca yang terdapat di dalam *Adang Stevenson*:

➤ Termometer Kering dan Basah

Termometer kering dan basah disokong secara tegak di dalam *Adang Stevenson*. Di sebelah kanan adalah termometer basah. Bebuli termometer basah dibalut dengan kain muslin dan diikat dengan benang. Benang tersebut dimasukkan ke dalam takungan yang telah diisi dengan air tulin. Lampiran B3 menunjukkan Termometer Kering dan Basah.

➤ Termometer Maksima dan Termometer Minima

Termometer maksima dan minima diletak di dalam *Adang Stevenson* dengan kedudukan yang hampir mendatar. Termometer maksima diletakan pada kedudukan bebulinya menghala ke bawah dengan membuat sudut kira-kira  $2^\circ$ . Lampiran B4 menunjukkan Termometer Maksima dan Termometer Minima.

- Termograf  
Fungsi Termograf adalah merekodkan suhu udara pada carta yang ada di dalamnya. Termograf beroperasi berdasarkan kepada kadar pengecutan dan pengembangan yang berbeza pada dua logam yang digunakan. Dua jalur logam dilekatkan bersama-sama dengan kuat pada kedua-dua belah permukaannya yang mendatar. Jalur logam ini kebiasaanya digulung berbentuk heliks. Jalur logam yang terdapat di bahagian luar mengembang lebih kecil daripada jalur logam bahagian dalam. Kenaikkan suhu akan menyebabkan helikus membuka gulungannya. Pergerakan ini dibesarkan oleh satu sistem tuas yang ringkas dengan menggunakan lengan pen yang panjang. Pen tersebut akan merekodkan suhu pada carta termograf. Lampiran B5 menunjukkan Termograf.
  
- Higoğraf  
Higoğraf adalah alat yang memberikan rekod yang selanjar bagi kelembapan bandingan. Ia mempunyai struktur yang hampir sama dengan Termograf. Lampiran B6 menunjukkan Higoğraf.

## 2) Tangki Sejatan

Tangki sejatan "*US class A*" digunakan untuk menyukat sejatan. Tolok Cangkuk diletak dalam tangki sejatan untuk menyukat paras air. *Cups* Anemometer diletak di sebelah permukaan tangki sejatan untuk mengukur tiupan angin. Lampiran B7 menunjukkan Penyukat Sejatan, Lampiran B8 pula menunjukkan Tolok Cangkuk dan Lampiran B9 menunjukkan *Cups* Anemometer.

- 3) Tolok Hujan  
Tolok hujan adalah alat yang digunakan untuk menyukat tadahan hujan. Lampiran B10 menunjukkan Tolok Hujan.
  
- 4) Perakam Hujan  
Perakam Hujan merupakan alat yang berfungsi secara otomatis untuk menyukat jumlah dan tempoh masa hujan. Lampiran B11 menunjukkan Perakam Hujan.
  
- 5) Perakam Penyinaran Matahari  
Perakam Penyinaran Matahari berfungsi sebagai penyukat tempoh matahari ketika cerah. Lampiran B12 menunjukkan Perakan Penyinar Matahari.
  
- 6) *Thedolite (Tracking Balloon)*  
Thedolite merupakan alat menguji cuaca dengan menggunakan *Tracking Balloon*. Lampiran B13 menunjukkan *Thedolite (Tracking Balloon)*.
  
- 7) Anemometer  
Anemometer adalah alat untuk mengukur kelajuan dan arah angin pada ketinggian piawai 10m di atas tanah. Lampiran B14 menunjukkan Anemometer.

## **BAB 3**

### **KAJIAN LITERATUR**

#### **3.1 Pengenalan**

Sebelum memulakan projek ini, kajian literatur mengenai iklim di Malaysia perlu dilakukan. Kajian literatur ini adalah bertujuan untuk mengetahui ciri-ciri iklim yang terdapat di Malaysia. Dengan memahami ciri-ciri iklim di Malaysia, kita dapat mengetahui jenis iklim, perubahan cuaca, dan hujan bermusim yang terdapat di Malaysia. Selain itu, dengan memahami ciri-ciri iklim di Malaysia ini juga sedikit sebanyak dapat dikaitkan dengan analisa yang akan dibuat mengenai hasil peramalan hujan yang akan dibuat.

Ciri-ciri iklim Malaysia ialah mempunyai suhu yang seragam, kelembapan yang tinggi dan hujan yang banyak. Anginnya pula pada amnya adalah lemah. Malaysia yang terletak di kawasan *doldrum* khatulistiwa amat jarang sekali mempunyai keadaan langit tidak berawan langsung walaupun pada musim kemarau yang teruk. Malaysia juga jarang mempunyai satu tempoh dalam beberapa hari dengan tidak ada langsung cahaya matahari kecuali pada musim monsun timur laut.

## **3.2 Taburan Hujan di Malaysia**

Corak tiupan angin bermusim bersama sifat topografi lokal menentukan corak taburan hujan di Malaysia. Semasa musim timur laut, kawasan yang terdedah seperti kawasan Pantai Timur Semenanjung Malaysia, kawasan Sarawak Barat dan kawasan pantai timur laut Sabah mengalami beberapa tempoh hujan lebat. Sebaliknya, kawasan pedalaman atau kawasan yang dilindungi banjaran gunung adalah secara relatifnya bebas dari pengaruh ini [1]. Taburan hujan di Malaysia mengikut musim akan diterangkan dalam bahagian seterusnya.

### **3.2.1 Perubahan Hujan Bermusim di Semenanjung Malaysia**

Perubahan hujan bermusim di Semenanjung Malaysia boleh dibahagikan kepada tiga jenis utama, iaitu:

- i. Bagi negeri-negeri di pantai timur Semenanjung Malaysia, pada bulan November, Disember dan Januari adalah merupakan bulan yang mempunyai hujan yang maksimum. Manakala bagi bulan Jun dan bulan Julai pula merupakan bulan kering di kebanyakan negeri.
- ii. Kawasan selain kawasan pantai barat daya Semenanjung Malaysia, corak hujan menunjukkan terdapatnya dua tempoh hujan maksimum dengan dipisahkan oleh dua tempoh hujan minimum. Hujan maksimum primer biasanya berlaku pada bulan Oktober hingga bulan November. Manakala hujan maksimum sekunder berlaku pada bulan April hingga bulan May. Di kawasan barat laut, hujan minimum primer berlaku pada bulan Januari

sehingga bulan Februari. Manakala hujan minimum sekunder berlaku pada bulan Jun hingga bulan Julai. Di lain-lain tempat, hujan minimum primer berlaku pada bulan Jun hingga bulan Julai manakala hujan minimum sekunder berlaku pada bulan Februari.

- iii. Corak hujan di kawasan pantai barat daya Semenanjung Malaysia lebih dicorakkan oleh kejadian 'Sumatras' pagi pada bulan Mei hingga bulan Ogos di mana corak hujan maksimum dan hujan minimum berganda tidak wujud. Bulan Oktober dan November adalah bulan yang mempunyai hujan maksimum. Manakala bulan Februari pula merupakan bulan yang mempunyai hujan minimum. Hujan maksimum berlaku pada bulan Mac, April dan bulan Mei. Bagi hujan minimum pula pada bulan Jun hingga bulan Julai tidak wujud atau kurang jelas.

### **3.2.2 Perubahan Hujan Bermusim di Sabah dan Sarawak**

Perubahan hujan bermusim di Sabah dan Sarawak boleh dibahagikan kepada lima jenis utama, iaitu:

- i. Kawasan pantai Sarawak dan timur laut Sabah mengalami corak hujan satu maksimum dan satu minimum. Kedua-dua kawasan mengalami hujan maksimum pada bulan yang sama iaitu Januari, manakala hujan minimum pada bulan yang berbeza. Di kawasan pantai Sarawak, hujan minimum berlaku pada bulan Jun atau Julai manakala kawasan timur laut pantai Sabah hujan minimum berlaku pada bulan April. Di bawah corak ini, kebanyakan hujan diterima pada bulan-bulan monsun timur laut iaitu pada bulan

Disember hingga Mac. Lebih daripada separuh dari hujan tahunan diterima di kawasan barat Sarawak.

- ii. Kawasan pedalaman Sarawak pula pada amnya mengalami taburan hujan tahunan yang agak sekata. Walaupun demikian, agak kurang atau sedikit hujan diterima semasa tempoh Jun hingga Ogos sesuai dengan kejadian angin lazim barat daya. Hujan tahunan tertinggi di Malaysia berlaku di cerun bukit kawasan pedalaman Sarawak. Kawasan Long Akah menerima hujan tahunan purata melebihi 5000 mm.
- iii. Kawasan barat laut pantai Sabah mengalami regim corak hujan dua maksima dan dua minima. Hujan maksimum primer berlaku pada bulan Oktober dan hujan maksimum skunder berlaku pada bulan Jun. Hujan minimum primer pula berlaku pada bulan Februari, manakala hujan minimum skunder berlaku pada bulan Ogos. Walaupun perbezaan jumlah hujan yang diterima pada dua bulan hujan maksimum adalah kecil, namun perbezaan jumlah hujan yang diterima pada hujan minimum primer adalah jelas lebih rendah berbanding skunder minimum. Di sesetengah tempat, perbezaan mencapai setinggi empat kali ganda.
- iv. Di kawasan tengah Sabah di mana keadaannya berbukit dan terlindung oleh banjaran gunung, hujan yang diterima adalah lebih rendah secara relatif berbanding dengan kawasan-kawasan lain serta taburannya agak sekata. Akan tetapi, dua maksima dan dua minima boleh diperhatikan. Pada amnya, dua minima berlaku pada bulan Februari dan Ogos manakala dua maksima berlaku pada bulan Mei dan Oktober.
- v. Kawasan selatan Sabah mengalami taburan hujan sekata. Jumlah hujan tahunan yang diterima boleh diperbandingkan dengan bahagian tengah Sabah. Bulan Februari hingga April adalah tempoh agak kering berbanding bulan-bulan lain.



### 3.3 Sistem Pernomboran Stesen Penyukat Hujan

Sesebuah stesen hidrologikal terdiri daripada tujuh digit nombor yang memberi makna seperti berikut [2]:

- i. Empat digit yang pertama mewakili lokasi grid stesen mengikut sistem penomboran grid Latitud  $6^0$  dan Longitud  $6^0$ .
- ii. Digit kelima mewakili jenis stesen.
- iii. Digit keenam dan ketujuh mewakili jenis stesen tertentu dalam lingkungan satu grid persegi.

Jadual 3.1(a) adalah contoh sistem penomboran stesen, manakala Jadual 3.1(b) pula ialah penomboran stesen mengikut jenis stesen.

**Jadual 3.1(a) :** Contoh sistem penomboran stesen.

Latitud	Longitud	Stesen atas peta
31	16	430

**Jadual 3.1(b) :** Pernomboran stesen mengikut jenis stesen.

Jenis Nombor	Keterangan
0 & 1	Stesen Hujan
2	Stesen Cuaca
3	Stesen Penyejat
4	Stesen Aliran Sungai
5	Stesen Kebergantungan Aliran Sungai
6	Stesen Kualiti Air Sungai

Digit ke-5 mewakili stesen aliran sungai berdasarkan jenis-jenis stesen di atas.

### **3.4 Teknik Peramalan**

Teknik peramalan merupakan langkah-langkah atau kaedah-kaedah yang digunakan untuk membuat sesuatu peramalan. Teknik peramalan merupakan asas untuk membuat perancangan pada masa hadapan.

#### **3.4.1 Pengenalan**

Peramalan merupakan suatu proses membuat penelahan atau ramalan suatu peristiwa yang akan datang. Peramalan juga merupakan suatu input kepada proses perancangan untuk suatu peristiwa yang tidak tahu apa natijahnya yang akan berlaku. Dengan itu, ia akan menyebabkan berlakunya pelbagai perkara yang boleh mempengaruhi keputusan sebenar terhadap peramalan yang dilakukan.

Bagi memilih teknik peramalan yang tepat, peramalan perlu mengambil kira beberapa faktor. Ini kerana kebiasaannya peramalan yang dibuat akan dikemaskini mengikut masa. Semakin lama tempoh peramalan yang dibuat, semakin besar perbezaan di antara nilai ramalan dengan nilai data yang sebenar. Antara faktor yang perlu diambil kira untuk memilih teknik peramalan yang tepat ialah:

- i. Tempoh atau jangkamasa peramalan.
- ii. Kesediaan data.
- iii. Kos peramalan.
- iv. Kesan peramalan.
- v. Jenis ramalan.
- vi. Usaha peramal.
- vii. Bentuk ramalan yang akan digunakan.

### **3.4.2 Peramalan Siri Masa**

Peramalan siri masa adalah berdasarkan kepada turutan yang seragam samada mengikut minggu, bulan, tahun, dan sebagainya. Peramalan data secara siri masa menganggap bahawa nilai peramalan untuk masa hadapan hanya diramalkan berdasarkan bacaan-bacaan dari masa lampau dan menganggap apa-apa juga bentuk pembolehubah lain walaupun boleh mempengaruhi peramalan ini boleh diabaikan.

Penganalisaan siri masa memerlukan data-data dari masa lampau dipecahkan kepada komponen-komponen kecil dan dilanjutkan ke depan. Peramalan siri masa terdiri daripada empat komponen, iaitu haluan, variasi bermusim, kitaran, dan variasi rawak.

#### **HALUAN (*TREND*)**

Haluan ialah bentuk umum pergerakan data sama ada ke bawah (menurun) atau ke atas (meningkat) terhadap masa. Perubahan terhadap aspek-aspek seperti pendapatan, populasi, taburan umur, atau pandangan budaya boleh mempengaruhi haluan.

#### **VARIASI BERMUSIM (*SEASONALITY*)**

Variasi bermusim ialah corak data yang berulang sendiri mengikut tempoh tertentu sama ada mengikut hari, minggu, bulan, atau sukuan tahun. Terdapat enam corak variasi bermusim yang biasa [3]: (Rujuk Jadual 3.2)

**Jadual 3.2:** Corak-corak variasi bermusim yang biasa

Tempoh Untuk Corak	Panjang 'Musim'	Jumlah 'Musim' Dalam Corak
Minggu	Hari	7
Bulan	Minggu	4
Bulan	Hari	28 – 31
Tahun	Sukuan	4
Tahun	Bulan	12
Tahun	Minggu	52

### **KITARAN (*CYCLES*)**

Kitaran adalah corak dalam data yang berlaku selang beberapa tahun. Biasanya kitaran ini terikat dengan kitaran perniagaan dan merupakan penting dalam analisis dan perancangan jangka pendek perniagaan. Peramalan perniagaan adalah rumit kerana mungkin dipengaruhi oleh peristiwa politik atau kemerosotan ekonomi dunia.

### **VARIASI RAWAK (*RANDOM VARIATION*)**

Variasi rawak adalah perubahan mendadak dalam data yang disebabkan oleh kejadian yang tidak dijangka terjadi. Variasi rawak mengakibatkan corak yang berbeza sekali dari pada yang sedia ada sekaligus tidak dapat diramalkan.

### 3.5 Metodologi Peramalan Box-Jenkins

Kaedah Box-Jenkins telah dibangunkan oleh G.E.P. Box dan G.M. Jenkins. Metodologi ini terdiri daripada 4 kaedah lelaran, iaitu [4]:

- i. Pengecaman kasar
- ii. Penganggaran
- iii. Semakan diagnosis
- iv. Peramalan

#### 3.5.1 Pengecaman Kasar

Proses pengecaman kasar menggunakan data lepas untuk mengecam model Box-Jenkins yang sesuai secara kasar. Proses ini dibuat ke atas model yang tidak bermusim dan disahkan kepegunannya. Antara model-model yang mungkin adalah seperti model autoregresif (AR), model purata bergerak (MA), atau model regresif bergerak (ARMA). Model Box-Jenkins boleh dikenalpasti melalui sifat-sifat fungsi autokolerasi sampel (ACF) dan fungsi separa autokolerasi sampel (PACF).

#### *Siri Masa Pegun dan Siri Masa Tak Pegun*

Siri masa yang hendak diramal perlu dikenalpasti bersifat pegun atau tidak bagi mengecam model Box-Jenkins. Data siri masa adalah senarai data-data yang direkodkan pada selang masa tertentu. Sekiranya statistik sesuatu siri masa itu seperti min,  $\mu$  dan varians,  $\sigma^2$  adalah dalam keadaan malar atau menghampiri malar sepanjang masa, maka

data-data tersebut adalah dalam bentuk siri masa pegun. Jika keadaan berlaku sebaliknya, maka data-data tersebut berbentuk siri masa tidak pegun.

Model Box-Jenkins hanya memperihalkan mengenai siri masa pegun sahaja. Jadi, data-data yang digunakan perlu bersifat siri masa pegun terlebih dahulu sebelum proses pengecaman kasar terhadap model tersebut dapat dibuat. Tetapi sekiranya data yang digunakan bersifat siri masa tidak pegun, data-data tersebut hendaklah diubah terlebih dahulu dengan membuat pembezaan peringkat pertama, kedua, dan seterusnya ke atas siri masa tersebut sehingga siri masa tersebut menunjukkan kepegunannya.

### **Autokolerasi Sampel**

Autokolerasi merupakan pengukuran statistik untuk mengenalpasti bagaimana siri masa berhubungkait sesama sendiri mengikut suatu jarak tempoh tertentu. Bilangan jarak tempoh dikenali sebagai susulan atau lag. Autokolerasi sampel ditandakan sebagai  $r_k$ . Bagi siri masa  $z_1, z_2, \dots, z_n$  [4]:

$$r_k = \frac{\sum [z_t - \bar{z}] [z_{t+k} - \bar{z}]}{\sum [z_t - \bar{z}]^2}$$

Autokolerasi sampel sentiasa berada dalam julat 1 dan  $-1$ . Apabila nilai ini menghampiri nilai 1, ini menunjukkan bahawa cerapan yang diasingkan oleh susulan selang unit masa mempunyai kecenderungan yang kuat untuk bergerak bersama secara linear dengan kecerunan positif. Sebaliknya, apabila nilai ini menghampiri nilai  $-1$ , ini menandakan cerapan tersebut mempunyai kecenderungan yang kuat untuk bergerak bersama secara linear dengan kecerunan negatif.

### *Telahan SAC*

SAC bagi siri masa tidak bermusim boleh dipenggal, iaitu apabila tonjolan pada susulan k wujud dalam SAC di mana pada ketika ini nilai  $r_k$  adalah lebih dari segi statistik [4].

$$t_{rk} = r_k / s_{rk} > 1.6$$

### *Menentukan Kepegunan Siri Masa Menggunakan SAC*

SAC boleh digunakan dalam menentukan nilai siri masa pegun. Terdapat pertikaian di antara perlakuan SAC dengan kepegunan bagi siri data tidak bermusim.

- Siri masa adalah bersifat pegun sekiranya nilai siri masa  $z_b, z_{b+1}, \dots, z_n$  samada terpenggal agak cepat atau berkurang agak cepat.
- Siri masa tidak pegun sekiranya  $z_b, z_{b+1}, \dots, z_n$  berkurang agak lambat.

### *Autokolerasi Separa Sampel*

Autokolerasi separa sampel merupakan satu lagi kaedah yang biasa dilakukan untuk mempamerkan pelbagai kelakuan yang berbeza. SPAC bagi siri masa tidak bermusim boleh terpenggal iaitu berlaku tonjolan pada susulan k dalam SPAC jika  $r_{kk}$  Autokolerasi Separa Sampel pada susulan k adalah lebih besar secara statistik. Untuk melihat tonjolan wujud pada susulan k, persamaan berikut haruslah dipenuhi [4].

$$t_{rk} = \frac{r_{kk}}{s_{rk}}$$

## *Teori Fungsi Autokolerasi Sampel dan Teori Fungsi Autokolerasi Separa*

Teori Fungsi Autokolerasi (TAC) bagi model adalah senarai teori autokolerasi  $\rho_1, \rho_2, \dots, \rho_n$  bagi pemerhatian siri masa. Teori Fungsi Autkolerasi Separa (TPAC) bagi model adalah senarai teori autokolerasi separa  $\rho_{11}, \rho_{22}$ , dan seterusnya bagi pemerhatian siri masa.

### *Pengenalpastian kasar model Box-Jenkins Tidak Bermusim*

- *Model Autoregresif (AR) Tidak Bermusim*

Bentuk umum:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t$$

dengan

$a_t$  = kejutan rawak semasa

$\delta$  = parameter yang hanya digunakan jia  $z$  secara statistik adalah berza dengan sifar.

$\phi$  = parameter yang tidak diketahui yang menghubungkan antara  $z_{t-1}, z_{t-2}, \dots, z_{t-p}$ .

Model ini sesuai digunakan apabila TAC berkurang dalam corak yang stabil dan TPAC mempunyai autokolerasi tidak sifar pada susulan 1, 2, ..., p dan bernilai sifar pada susulan selepas susulan p. Bagi data siri masa pegun pula fungsi autokolerasi sampel berkurang dalam corak yang stabil dan fungsi separa autkolerasi sampel mempunyai tonjolan pada susulan 1, 2, ..., p dan terpenggal selepas susulan p.

- *Model Purata Bergerak (MA) Tidak Bermusim*

Bentuk umum:

$$z_t = \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

dengan

$a_t$  = kejutan rawak semasa



$\theta =$  parameter yang tidak diketahui yang menghubungkan antara  $z_t$  dengan  $a_{t-1}, a_{t-2}, \dots, a_{t-q}$ .

$\delta =$  pemalar yang digunakan hanya jika  $z$  secara statistik adalah berbeza dengan sifar.

Model ini hanya sesuai digunakan apabila TAC bernilai bukan sifar pada susulan 1, 2, ..., q dan bernilai sifar selepas susulan q serta TPAC berkurang secara stabil. Bagi data siri masa pegun pula fungsi autokolerasi sampel mempunyai tonjolan pada susulan 1, 2, ..., q dan terpenggal selepas susulan q dan fungsi separa autokolerasi sampel berkurang dalam corak yang stabil.

- *Model Autoregresif Purata Bergerak (ARMA) Tidak Bermusim*

Bentuk Umum:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Model ini hanya sesuai digunakan apabila TAC berkurang dalam keadaan eksponen lembap sementara TPAC berkurang dalam keadaan yang dikuasai oleh pereputan eksponen lembap. Bagi data siri masa pegun pula model ini sesuai digunakan apabila fungsi separa autokolerasi sampel berkurang dalam keadaan eksponen dan fungsi separa autokolerasi sampel berkurang dalam keadaan yang dikuasai oleh pereputan eksponen lembap.

### 3.5.2 Penganggaran

Langkah ini adalah untuk menganggarkan nilai-nilai parameter model yang telah dikenalpasti secara kasar pada langkah pengesanan kasar. Antara perkara yang dipertimbangkan adalah syarat-syarat kepegunan dan keterserongan, penganggaran nilai

awal dan akhir. Selepas itu, hipotesis t dan nilai kebarangkalian dilakukan untuk menimbang kepentingan parameter model.

### *Penyemakan Ke Atas Parameter*

Penyemakan dilakukan dengan menggunakan nilai t dan juga nilai kebarangkalian. Nilai  $\theta$  adalah dianggap sebagai sebarang parameter dalam model Box-Jenkins dan  $\theta$  titik anggaran bagi  $\theta$  sementara  $s_{\theta}$  adalah ralat piawai bagi titik anggaran  $\theta$ . Nilai t dikira melalui persamaan [4]:

$$t = \frac{\hat{\theta}}{s_{\hat{\theta}}}$$

Ujian hipotesis t dilakukan di mana  $H_0 : \theta = 0$  dan  $H_1 : \theta \neq 0$ . Hipotesis  $H_0 : \theta = 0$  dilakukan dan  $H_1 : \theta \neq 0$  diterima dengan menentukan nilai kebarangkalian ralat jenis 1 sebagai  $\alpha$  jika dan hanya jika syarat berikut dipenuhi [4].

- i.  $|t_{\hat{\theta}}| > t_{\alpha/2}^{(n-np)}$  di mana  $|t_{\hat{\theta}}| > t_{\alpha/2}^{(n-np)}$  atau  $|t_{\hat{\theta}}| < -t_{\alpha/2}^{(n-np)}$
- ii. Nilai kebarangkalian  $< \alpha$ .

Jika nilai mutlak t adalah lebih besar maka parameter  $\theta$  ini menunjukkan keyakinan yang kukuh bahawa parameter  $\theta$  penting dan disertakan dalam model.

### 3.5.3 Semakan Diagnosis

Penyemakan diagnosis dilaksanakan untuk mengetahui sama ada pemalar perlu dimasukkan ke dalam model dan juga menentukan sama ada model yang dibangunkan sudah memadai. Dua kaedah statistik iaitu [4]:

- Statistik Box-Pierce  $Q = n' \Sigma r_2^1(a)$
- Statistik Ljung-Box  $Q = n' (n'+2) \Sigma(n'-1) r_1^2$  di mana  $n = n - (d + LD)$  dengan  $n$  bilangan cerapan dalam siri masa asal,  $L$  adalah bilangan cerapan dalam siri masa,  $L$  adalah bilangan musim dalam satu tahun (jika bermusim),  $d$  dan  $D$  adalah darjah pembezaan bermusim dan tidak bermusim yang digunakan untuk menterjemahkan nilai siri masa asal kepada siri masa pegun  $r_1^2(a)$  adalah kuasa dua bagi  $r_1(a)$ , autokolerasi sampel bagi ralat pada susulan 1.

Model diuji dengan cara menyemak nilai  $Q^*$  sekiranya lebih besar dari  $\chi^2_{(\alpha)}(K - n_p)$ , titik pada skala taburan Chi kuasa dua yang mempunyai  $K - n_p$  darjah kebebasan hingga terdapat luas  $\alpha$  di bawah lengkung taburan di atas titik ini dan juga jika nilai kebarangkalian adalah kurang dari  $\alpha_1$  dengan nilai kebarangkalian merupakan luas di bawah lengkung taburan Chi kuasa dua yang mempunyai  $K - n_p$  darjah kebebasan ke kanan  $Q^*$  maka model ini adalah tidak memadai.

### 3.5.4 Peramalan

Setelah model yang terbaik diperolehi serta penganggaran parameter dan pemalar serta penyemakan diagnosis selesai dilakukan, seterusnya proses peramalan akan

dilakukan. Oleh kerana terdapat  $n$  data siri masa yang dicerap maka titik ramalan bermula dari titik  $n$  yang tersebut iaitu [4]:

$$Y_{n+1}(n)$$

di mana,

$n$  = bilangan data terakhir yang dicerap

$t$  = masa data yang diramalkan ( $t \geq 1$ )

Selang keyakinan ramalan pada  $100(1-\alpha)\%$  dikira daripada  $n$  data siri masa dalam tempoh  $(n+1)$  adalah [4]:

$$[Y_{n+1}(n) \pm t^{(n-n_p)} SE_{n+1}(n)]$$

di mana  $SE_{n+1}(n)$  adalah ralat piawai peramalan. Memandangkan  $SE_{n+1}(n)$  bergantung kepada ralat piawai,  $s$ , maka  $SE_{n+1}(n)$  boleh digantikan dengan  $s = \sqrt{SSE/(n-n_p)}$  di mana  $SSE = \sum(y_1 - \hat{y}_1)^2$

### 3.6 Metodologi Peramalan Rangkaian Neural

Rangkaian neural merupakan sistem pemrosesan maklumat yang mempunyai ciri-ciri tertentu yang menyamai dengan rangkaian neural *biological* (sistem saraf). Rangkaian neural telah dibangunkan sebagai model matematik yang menyeluruh mengenai kognisi manusia atau biologi neural berasaskan andaian berikut:

- i. Pemrosesan maklumat yang berlaku pada kebanyakan elemen-elemen yang dipanggil neuron.
- ii. Petunjuk yang melintasi antara neuron melalui laluan perhubungan.

- iii. Setiap laluan perhubungan mempunyai pemberat yang berkaitan, yang mana ia terdapat pada rangkaian neural biasa, multiaras dan pada penghantaran signal.
- iv. Setiap neuron mengandungi fungsi penggiatan (biasanya tidak linear) pada rangkaian input (jumlah pemberat signal input) untuk mengenalpasti signal output.

Rangkaian neural dicirikan dengan tiga perkara berikut [5]:

- i. Bentuk hubungan antara neuron (dipanggil sinapsis).
- ii. Kaedah untuk mengenalpasti pemberat pada sambungan (dipanggil latihan atau pembelajaran, algoritma).
- iii. Fungsi penggiatan.

Rangkaian neural merupakan suatu teknologi yang membolehkan komputer mempelajari atau melakukan pemrosesan berdasarkan kepada pengalaman atau data yang diterima. Ia merupakan pelaksanaan algoritma yang diilhamkan daripada pemikiran manusia dengan meniru kemampuan otak manusia mengesan sesuatu atau membuat keputusan daripada pengalaman yang lepas [5]. Rangkaian neural juga menyediakan pendekatan yang berkesan untuk diaplikasi dalam pelbagai bidang. Rangkaian neural ini pada asasnya terdiri daripada beberapa unit pemrosesan. Setiap unit menerima isyarat input melalui talian berpemberat, dan memberi respon kepada talian berpemberat sebagai output.


Suatu rangkaian neural terdiri daripada sebilangan nod atau unit yang dihubungkan antara satu sama lain yang mempunyai kaitan. Setiap hubungan mempunyai nilai pemberat yang tersendiri. Nilai pemberat akan sentiasa dikemaskini apabila proses pembelajaran pada rangkaian dilakukan. Pemberat akan sentiasa diselaraskan supaya kelakuan input dan output pada rangkaian lebih hampir dengan

prasarana yang memberikan nilai input tersebut. Untuk membina suatu rangkaian neural, kita perlu menetapkan bilangan unit pemprosesan pada aras input dan output serta jenis unit yang bersesuaian dengan bentuk rangkaian yang akan digunakan. Rangkaian neural dianggap ideal dalam beberapa perkara kerana berbanding manusia, rangkaian neural tidak pernah bosan dengan tugas yang dilakukan.


Frank Rosenblatt telah memperkenalkan rangkaian dua aras yang dibina untuk mengecam pola, iaitu pada tahun 1957. Ia dikenali sebagai *perseptron*. Kemudian, rangkaian Hopfield, Boltzman, Fungsi Asas Radial dan Rangkaian Rambatan ke Belakang pula diperkenalkan. Rangkaian rambatan ke belakang adalah merupakan antara salah satu kaedah yang paling popular [6].

### **3.6.1 Konsep Asas Senibina Rangkaian Neural**


Konsep asas yang mendokong pembangunan kaedah rangkaian neural dapat membantu kita untuk memahami rangkaian neural dengan lebih mudah. Elemen yang paling asas sekali dalam sistem otak manusia ialah sejenis sel spesifik yang membolehkan manusia berfikir, menyimpan ingatan, dan menggunakan pengalaman lepas dalam setiap pergerakan manusia. Sel tersebut ialah neuron. Setiap satu neuron boleh berinteraksi dengan lebih 300 000 neuron yang lain. Neuron merupakan pemproses asas rangkaian neural. Ia adalah proses mudah apabila unit-unit neuron menerima dan memproses signal dari neuron lain melalui jalan masuk, iaitu *dendrite*. Sekiranya kombinasi neuron cukup kuat, ia akan menghasilkan signal output ke jalan output yang dipanggil *axon* yang memisahkan dan menghubungkan sesuatu neuron dengan jalan masuk ke neuron lain dengan *synapse* sebagai penghubung. Manakala kerja memproses kesemua signal input dijalankan oleh *soma*. Proses rangkaian neural pada sistem saraf manusia ini ditunjukkan dalam Rajah 3.1 dan Rajah 3.2. Rajah 3.3 pula menunjukkan model neuron. Manakala Rajah 3.4 pula menunjukkan aliran neuron.



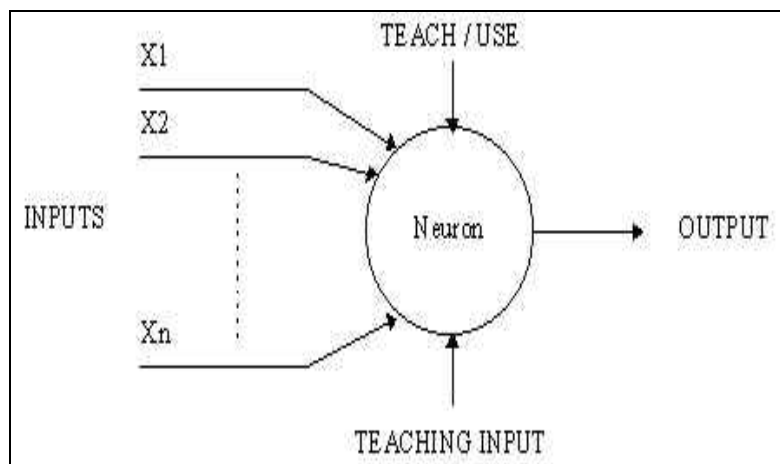
**Rajah 3.1** Komponen neuron



**Rajah 3.2** Synaps



**Rajah 3.3** Model neuron



**Rajah 3.4** Neuron


### 3.6.2 Struktur Rangkaian

Dua struktur rangkaian yang paling utama ialah rangkaian berjenis suapan ke depan (*feedforward*) dan rangkaian berjenis suapan ke belakang atau rangkaian jadi semula (*recurrent*). Rangkaian suapan ke depan dibangunkan dengan membina set



neuron yang disusun dan dibahagikan kepada dua atau lebih aras. Secara umumnya terdapat dua aras utama iaitu aras input dan aras output, yang setiap satunya mengandungi sekurang-kurangnya satu neuron. Neuron dalam aras input adalah berdasarkan hipotesis yang mana neuron itu sendiri tidak mengandungi apa-apa input dan ianya tidak diproses dengan cara apa pun. Manakala output didefinisikan dengan rangkaian inputnya. Kebiasaanya terdapat satu atau lebih aras tersembunyi yang ditempatkan di tengah-tengah kedua-dua aras input dan aras output tersebut.

Manakala bagi suapan ke depan pula bermaksud kesemua maklumat mengalir sehalu sahaja. Input untuk satu-satu neuron pada setiap aras datang secara eksklusif pada aras berikutnya. Selain itu, ia sentiasa mempunyai anggapan yang disebut *bias* atau nilai ambang yang bernilai antara 1 hingga 0. Neuron tanpa nilai ambang biasanya digunakan untuk fungsi linear. Nilai sesuatu neuron akan mempengaruhi oleh nilai pemberat yang didarabkan dengan setiap nilai input untuk memberi nilai output. Input rangkaian adalah jumlah nilai pemberat. Rajah 3.5 menunjukkan contoh neuron yang mempunyai nilai ambang. Rajah 3.6 pula adalah contoh untuk menerangkan neuron tidak yang mempunyai nilai ambang.



**Rajah 3.5** Neuron dengan nilai ambang

Katakan bilangan  $n$  input ialah  $\{p_i, I = 0, \dots, n-1\}$ , output neuron akan dikira sebagai:

$$\text{Output } (a) = f(\text{rangkaian}) = f\left(\sum_{i=1}^n w_i p_i + b\right)$$

Di mana


$p$  = input

$w$  = pemberat

$f$  = fungsi penggiatan

$a$  = output

$b$  = nilai ambang



**Rajah 3.6** Neuron tanpa nilai ambang

Katakan bilangan  $n$  input ialah  $\{p_i, I = 0, \dots, n-1\}$ , output neuron akan dikira sebagai:

$$\text{Output } (a) = f(\text{rangkaian}) = f\left(\sum_{i=1}^n w_i p_i\right)$$

Di mana

$p$  = input

$w$  = pemberat

$f$  = fungsi penggiatan

$n$  = output

Setiap neuron dengan nilai ambang kebiasaannya terdiri daripada:

- i. Input  $p$ . Neuron boleh mengandungi antara satu hingga  $\infty$  input.
- ii. Setiap input mempunyai pemberat  $w$  yang telah diwakilkan.
- iii. Penjumlahan pemberat dan input akan dicampurkan dengan nilai ambang  $b$ .
- iv. Hasil penjumlahan  $x$  akan diberikan fungsi penggiatan  $f$  untuk menghasilkan output  $a$ . Fungsi penggiatan yang dipilih akan menentukan hasil output yang berbeza mengikut kehendak rangkaian.

Bagi masalah yang lebih rumit, rangkaian satu aras dianggap tidak efisien. Sebaiknya meletakkan aras tersembunyi pada rangkaian dan menjadikan rangkaian berbentuk multiaras. Bilangan aras tersembunyi boleh terdiri daripada satu atau lebih.

### 3.6.3 Algoritma Pembelajaran

Talian berpemberat akan menyimpan kesemua pengetahuan yang dimiliki oleh satu rangkaian neural. Terdapat beberapa jenis algoritma pembelajaran yang boleh digunakan bagi melatih rangkaian neural iaitu:

- i. Kaedah Pembelajaran Berseliaan  
Merupakan proses pembelajaran yang melibatkan pemberian pola input satu demi satu kepada rangkaian neural. Kemudian diberi pola output sebenar pada rangkaian bagi tujuan perbandingan dengan output sasaran. Pembelajaran seliaan mesti mempunyai satu set pola data latihan, satu set

data pentahkikan, topologi pola input dan output, bilangan neuron dan saiz aras tersembunyi supaya bersesuaian dengan masalah yang berkaitan.

ii. Kaedah Pembelajaran Tanpa Seliaan

Merupakan suatu cara pembelajaran yang menyelaraskan pemberat tanpa perbandingan dengan output sasaran. Tiada tanda pembelajaran secara suap di dalam penyelarasan pemberat. Kaedah ini juga dikenali sebagai *swa-organisasi*.

iii. Kaedah Pembelajaran Rangsangan

Merupakan suatu kaedah pembelajaran yang berada antara pendekatan kaedah pembelajaran berselidikan dengan kaedah pembelajaran tanpa seliaan. Kaedah pembelajaran rangsangan ini memerlukan input dan hanya gred atau isyarat ganjaran sebagai output. Jika dibandingkan dengan kaedah pembelajaran yang lain, kaedah ini kurang popular kerana ia mengambil masa yang lama dan terlalu kompleks. Walau bagaimanapun, kaedah pembelajaran ini berupaya melatih sistem modular bagi hubungan yang besar untuk rangkaian. Selain itu, jika dibandingkan, keperluan data latihan adalah longgar jika berbanding dengan kaedah pembelajaran seliaan.

### **3.6.4 Fungsi Penggiatan**

Fungsi penggiatan merupakan fungsi penghantar matematik yang mengenalpasti pada peringkat manakah sesuatu data yang dimasukkan harus diberi penekanan. Fungsi matematik bagi pelbagai fungsi penggiatan adalah seperti dalam Jadual 3.2.

**Jadual 3.3 : Fungsi matematik penggiatan**

<b>Fungsi</b>	<b>Persamaan</b>
Logistik	$f(x) = 1 / \{1 + \exp (-x)\}$
Linear	$f(x) = x$
Tanh	$f(x) = \tanh (x)$
Tanh15	$f(x) = \tanh (1.5x)$
Sin	$f(x) = \sin (x)$
Symmetric Logistic	$f(x) = 2 / \{1 + \exp (-x)\} - 1$
Gaussian	$f(x) = \exp (-x^2)$
Gaussian Complement	$f(x) = 1 - \exp (-x^2)$

Di dalam kajian ini, terdapat dua fungsi penggiatan yang dipilih, iaitu:


- i. Fungsi Linear ( Fungsi Linear) – Fungsi ini akan digunakan pada aras output.
- ii. Fungsi Sigmoid ( Fungsi Bukan Linear ) – Fungsi yang akan digunakan pada aras tersembunyi.

### Fungsi Linear

Fungsi ini ditakrifkan sebagai:

$$f(x) = x \begin{cases} 1 & \text{jika } x \geq 0 \\ 0 & \text{jika } x < 0 \end{cases}$$

Rajah 3.7 menunjukkan gambaran bagi fungsi linear.




**Rajah 3.7** Fungsi linear

### Fungsi Sigmoid

Fungsi ini di takrifkan oleh:

$$f(x) = (1 + e^{-x})^{-1}$$

Nilai input bagi fungsi penggiatan ini terdiri antara sebarang nilai positif dan negatif, fungsi ini akan menghasilkan nilai antara -1 dan 1. Fungsi penggiatan ini biasanya digunakan di dalam algoritma rambatan ke belakang. Rajah 3.8 menggambarkan fungsi sigmoid.



**Rajah 3.8** Fungsi sigmoid

### 3.6.5 Senibina Rangkaian


Senibina rangkaian adalah merupakan susunan nod-nod rangkaian dan bentuk hubungan antara nod-nod rangkaian di dalam rangkaian nural. Senibina rangkaian yang terdapat dalam rangkaian neural ialah:

➤ Perseptron Satu Aras

Perseptron satu aras terdiri daripada lapisan input dan lapisan output. Ia tidak mempunyai lapisan tersembunyi. Setiap neuron di dalam lapisan input berhubung dengan neuron di dalam lapisan output dan setiap sambungan di antara lapisan input dan output disesuaikan dengan rangkaian. Output neuron dari perseptron merupakan hasil input neuron tersebut. Satu aras neuron secara skematiknya ditunjukkan dalam rajah 3.9 dengan  $n$  input yang dilabelkan dari  $p_1$  ke  $p_n$ .

Walau bagaimana bentuk input sekalipun, perseptron akan mengeluarkan nilai set output yang terdapat di dalam lapisan output tetapi ia bergantung kepada bentuk input dan nilai yang terdapat pada sambungan.

Perseptron satu aras dapat menyelesaikan masalah secara linear, tetapi terdapat banyak kelas masalah yang tidak dapat dipisahkan secara linear dan juga yang tidak boleh di atasi dengan menggunakan perseptron satu aras. Untuk menyelesaikan masalah yang lebih rumit, senibina rangkaian perseptron multiaras diperlukan.



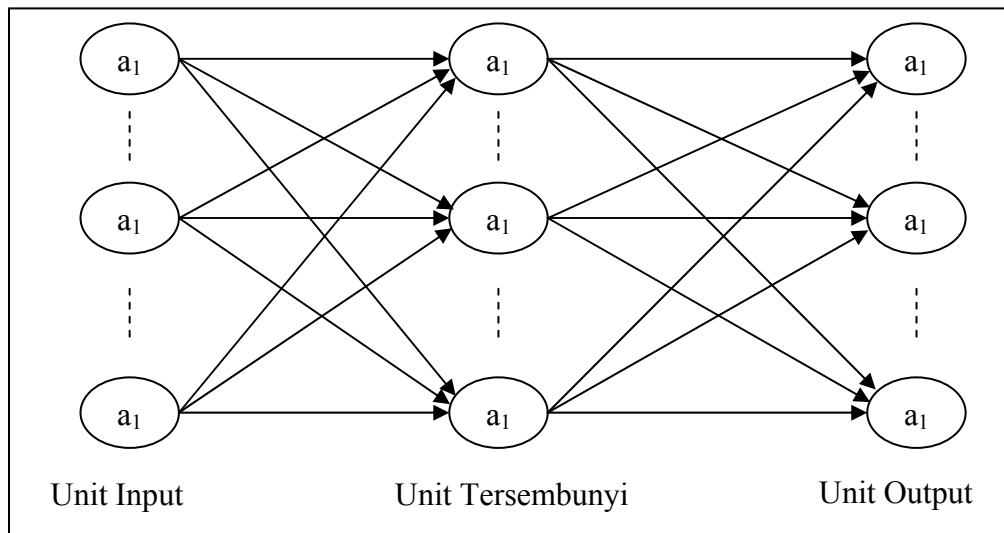
**Rajah 3.9** Rangkaian satu aras

➤ Perseptron Multiaras

Perseptron multiaras mempunyai dua perbezaan dengan perseptron satu aras. Perbezaan tersebut ialah:



- i. Perseptron multilaras mempunyai lapisan tambahan pada neuron iaitu di antara lapisan input dan output, yang dikenali sebagai lapisan tersembunyi. Lapisan ini menambah kekuatan proses pembelajaran pada Perseptron Multilaras. Rajah 3.10 menunjukkan rangkaian perseptron multilaras.



**Rajah 3.10** Rangkaian multilaras

- ii. Perseptron multilaras ini menggunakan kaedah pemindahan, pengaktifan dan fungsi untuk mengubah input pada neuron. Pengaktifan lapisan output dan lapisan tersembunyi pada neuron adalah sama seperti yang terdapat pada perseptron satu aras. Fungsi pemindahan pula merupakan fungsi yang tidak linear seperti fungsi sigmoid. Fungsi sigmoid ini dipilih kerana algoritma ini memerlukan fungsi tindak balas secara berterusan.

Pemberat dan bias di dalam rangkaian biasanya dikenali dengan nilai rawak yang kecil. Seterusnya bentuk latihan digunakan di dalam unit input dan pengaktifan

neuron pada lapisan tersembunyi yang pertama dikira. Output yang dihasilkan oleh neuron-neuron ini melalui fungsi permindahan dan seterusnya ke neuron yang berada pada lapisan berikutnya. Proses ini berulang pada setiap lapisan sehingga isyarat output dari neuron pada lapisan input diperolehi.

Jika output yang dihasilkan oleh rangkaian adalah tepat, maka penyambungan neuron output kepada neuron input adalah tidak berubah. Jika output rangkaian lebih besar daripada output yang dikehendaki pada mana-mana nod, penyambungan di antara neuron itu dengan semua neuron input berkurangan. Manakala jika output lebih kecil daripada nilai yang sepatutnya, nilai penyambungan semakin bertambah.

### **3.6.5.1 Faktor-Faktor yang Mempengaruhi Prestasi Rangkaian**

Antara faktor-faktor yang mempengaruhi prestasi rangkaian ialah:

- i. Kadar pembelajaran ( $lr$ )  
Dengan membuat penentuan yang sesuai terhadap nilai kadar pembelajaran, saiz perubahan nilai pemberat yang dibuat pada setiap lelaran dapat ditentukan dan disamping itu ia dapat mempengaruhi masa pemusatan rangkaian. Pemilihan nilai yang terlalu kecil akan menyebabkan tempoh untuk penumpuan agak lama dan berkemungkinan juga tidak berlaku penumpuan. Kadar pembelajaran boleh dibayangkan sebagai jarak langkah yang diambil oleh algoritma untuk mengesan permukaan ralat bagi setiap lelaran [7].
- ii. Pemalar momentum ( $mc$ )  
Dengan menambah suatu nilai momentum pada ungkapan kecerunan dapat memperbaiki kadar pemusatan rangkaian. Penambahan sebahagian kecil

perubahan nilai pemberat terdahulu kepada perubahan pemberat semasa dapat membantu memudahkan laluan penurunan pencarian ralat dengan menghalang berlakunya perubahan yang keterlauan pada kecerunan [7].

iii. Penjelmaan atau penskalaan data

Dengan membuat penjelmaan terhadap data, rangkaian dapat di elakkan daripada masalah pengiraan semasa proses pembelajaran rangkaian.

### **3.6.6 Pendekatan Kaedah Rambatan Ke Belakang**

Kaedah rambatan ke belakang bermaksud rangkaian yang dibina secara multiaras, rangkaian suapan ke depan (*feedforward*) yang menerima latihan rambatan ke belakang yang menyelesaikan kebanyakan masalah. Kaedah ini biasanya mempunyai satu aras input, satu aras output dan satu atau lebih aras tersembunyi. Masih belum ada teori yang menyatakan had terhadap bilangan aras tersembunyi, tetapi biasanya rangkaian mempunyai hanya satu atau dua aras tersembunyi. Kesemua nod dalam aras berhubungan antara satu sama lain dengan nod dari aras yang sebelumnya dan aras selepasnya. Pertalian pemberat antara dua nod menggambarkan kekuatan perhubungan antara nod-nod tersebut. Penentuan pemberat ini dilakukan secara rawak yang merupakan fokus utama dalam proses rangkaian neural.

Matlamat utama algoritma rambatan ke belakang ini adalah untuk meminimumkan jumlah ralat kuasa dua bagi output yang dikira oleh rangkaian [5]. Tiga peringkat latihan bagi algoritma ini ialah, pertama suapan ke hadapan untuk membentuk input latihan. Kedua ialah pengiraan dan rambatan ke belakang bagi mengira ralat. Dan ketiga pula penyesuaian nilai bagi pemberat.

Terdapat beberapa komponen yang perlu dipertimbangkan apabila membangunkan model rangkaian neural, iaitu:

- i. Saiz rangkaian iaitu bilangan nod input, nod output, dan nod tersembunyi.
- ii. Nilai awalan pemberat, nilai parameter pembelajaran (momentum dan kadar pembelajaran).
- iii. Pemilihan fungsi keaktifan atau penggiatan samada linear, sigmoid, tangen dan sin.
- iv. Algoritma pembelajaran.
- v. Pembentukan set data latihan dan pengujian.
- vi. Cara menganalisis data.

Fungsi penggiatan untuk rambatan ke belakang mempunyai ciri-ciri yang bersifat berterusan. Fungsi penggiatan tidak berubah-ubah dan ia juga tidak bertambah secara monotonik. Fungsi penggiatan yang selalu digunakan untuk model ini adalah fungsi sigmoid yang mempunyai nilai binari 0 dan 1 (0,1) dengan rumus:

$$f(x) = (1 + e^{-x})^{-1}$$


dengan nilai  $f'(x) = f(x)[1 - (f(x))]$

### 3.6.6.1 Proses Pembelajaran

Proses pembelajaran dalam rangkaian neural bertujuan untuk mempelajari corak output daripada bentuk data input. Dalam proses pembelajaran ini, rangkaian sentiasa dibekalkan dengan data dari persekitaran yang sebenar iaitu output yang telah diketahui. Bagi setiap bentuk data, rangkaian membuat ramalan output dengan menggunakan satu nilai pemberat pertalian permulaan. Jika ramalan benar, rangkaian seterusnya akan

mengalih kebentuk data yang lain. Tetapi jika ramalan yang dibuat tidak tepat, pemberat yang lain akan dimasukkan. Seterusnya peramalan baru akan dibuat dan diperiksa ketepatannya. Proses ini akan berulang sehingga peramalan tepat di perolehi. Proses pembelajaran merupakan proses penyesuaian pemberat sehingga peramalan output yang tepat diperolehi.

Proses pembelajaran umumnya memerlukan bilangan lalaran yang banyak untuk rangkaian melakukan pengecaman dengan lebih tepat. Jika terlalu banyak lalaran, rangkaian akan menjadi kurang stabil. Setiap unit proses pada aras output menghasilkan satu nilai nyata yang kemudiannya dibandingkan dengan data output sasaran sebagaimana ditetapkan dalam set latihan. Nilai ralat dikira bagi setiap unit pemprosesan pada aras output. Kemudian pemberat diselaraskan untuk semua talian yang menuju ke aras output. Nilai ralat akan dihitung pula bagi semua unit pemprosesan pada aras tersembunyi. Pemberat tersebut kemudian diselaraskan untuk semua talian yang menuju ke aras tersembunyi. Proses ini berterusan sehingga nilai pemberat mencapai nilai yang optimum dan ralat yang wujud pada aras tersembunyi dan aras output adalah terkecil atau menghampiri sifar. Rajah 3.11 menunjukkan pengoperasian rambatan ke belakang.



**Rajah 3.11** Operasi rambatan ke belakang

dengan	$p_1$ dan $p_2$	adalah neuron pada aras input.
	$x$	adalah neuron pada aras input.
	$z$	adalah neuron pada aras tersembunyi (fungsi sigmoid).
	$y$	adalah neuron pada aras output (fungsi linear).
	$w^1_{21}, w^1_{12}, w^1_{11}, w^1_{22}$	adalah pemberat antara input dan aras tersembunyi.
	$w^2_{11}, w^2_{21}, w^2_{12}, w^2_{22}$	adalah pemberat antara aras tersembunyi dan output.
	$b^1_1, b^1_2$	adalah nilai ambang.
	$a^1_1, a^1_2$	adalah output pada aras tersembunyi.
	$a^2_2, a^2_1$	adalah output.
	$e_1, e_2$	adalah ralat output.

Rangkaian rambatan ke belakang dilatih dengan teknik pembelajaran seliaan. Rangkaian ini diberi satu siri pasangan pola. Setiap padanan terdiri daripada pola input dan output sasaran untuk mewakili pengelasan bagi pola input. Setiap pola adalah vektor bagi nombor nyata. Rangkaian mungkin diberi satu siri pola input bersama dengan pengelasan bagi pola output yang direka.

### 3.6.7 Langkah-Langkah Peramalan Menggunakan Kaedah Rangkaian Neural

Proses pembangunan rangkaian neural buatan dianggap masih menyerupai metodologi rekabentuk senibina sistem maklumat tradisional berasaskan komputer. Tetapi sebahagian langkah adalah unik kepada aplikasi rangkaian neural dan memerlukan pertimbangan tambahan. Oleh itu, terdapat sembilan langkah dalam membangunkan aplikasi rangkaian neural [8].

Langkah 1 : Kenalpasti apa yang hendak diramalkan

Langkah pertama ialah mengenalpasti apa yang ingin diramalkan. Di dalam fasa ini, taburan hujan di negeri Johor mengikut hari akan diramalkan. Untuk mengenalpasti samada hari tersebut hujan atau tidak. Ia bermaksud, di dalam langkah ini, perkara yang akan diramalkan ialah taburan hujan untuk lima hari berikutnya.

Langkah 2 : Mengumpul data yang berkaitan

Data taburan hujan yang diperolehi adalah daripada Bahagian Hidrologi dan Sumber Air, Jabatan Pengairan dan Saliran Johor (JPS). Data adalah dalam tempoh tiga tahun, iaitu dari Januari 2000 hingga Julai 2002. Bacaan data hujan ialah dalam bentuk harian.

Langkah 3 : Menggabungkan dan menyusun data supaya lebih bermakna

Data yang diperolehi perlu diproses dan kemudian digabungkan supaya lebih bermakna dengan mengguna fungsi penggiatan sigmoid dan penjelmaan. Penjelmaan linear digunakan di dalam projek ini untuk menyesuaikan keputusan algoritma.

Fungsi linear :  $f(x) = x$

Penjelmaan :  $X_n = \frac{X_o - X_{\min}}{X_{\max} - X_{\min}}$

di mana  $X_o$  adalah nilai asal bagi  $X$  (sebelum dijelmakan).  
 $X_n$  adalah nilai baru bagi  $X$  (nilai yang dijelmakan).

$X_{min}$  adalah nilai  $X$  paling minima dalam sampel data.

$X_{max}$  adalah nilai  $X$  paling maksima dalam sampel data.

Penukaran semula:  $X_{asal} = X_{jelma} (X_{max} - X_{min}) + X_{min}$

di mana  $X_{asal}$  adalah nilai asal bagi  $X$  (sebelum dijelmakan).

$X_{jelma}$  adalah baru bagi  $X$  (nilai yang dijelmakan).

$X_{max}$  adalah  $X$  paling maksima dalam sampel data.

$X_{min}$  adalah  $X$  paling minima dalam sampel data.

Contoh:

$$1 \text{ Jan } 2000 = 14.5$$

$$\begin{aligned} \text{Penjelmaan} &= X_n = \frac{X_o - X_{min}}{X_{max} - X_{min}} \\ &= \frac{14.5 - 0.0}{89.5 - 0.0} \\ &= 0.1620 \end{aligned}$$

$$\begin{aligned} \text{Penukaran semula} &= X_{asal} = X_{jelma} (X_{max} - X_{min}) + X_{min} \\ &= 0.1620 (89.5 - 0.0) + 0.0 \\ &= 14.4990 \end{aligned}$$



Langkah 4 : Membuat penetapan data untuk latihan, pengujian dan pengesahan.

Terdapat beberapa kaedah yang disarankan untuk pembelajaran atau latihan, pengujian dan pengesahan. Antaranya 80 peratus untuk pembelajaran dan 20 peratus untuk pengujian dan pengesahan, atau 70 peratus pembelajaran dan 30 peratus untuk pengujian dan pengesahan, atau 2/3 data untuk latihan dan 1/3 untuk pengujian dan pengesahan. Daripada data taburan hujan yang ada, data tahun 2000 digunakan untuk pembelajaran, tahun 2001 digunakan untuk pengesahan dan data bagi tahun 2002 digunakan untuk peramalan.

Langkah 5 : Memilih senibina rangkaian yang bersesuaian dengan masalah

Peringkat ini menetapkan bilangan nod input, nod tersembunyi, dan nod output. Jumlah neuron yang terlibat dan jumlah aras yang akan digunakan turut dikenalpasti. Di dalam projek ini, nod input adalah 7 hari berturut sebagai bilangan input, kemudian 5 hari berikutnya sebagai bilangan output. Lampiran C menunjukkan contoh sebahagian data taburan hujan yang diterima dari pihak JPS. Lampiran D pula menunjukkan contoh sebahagian data yang disusun.

Manakala bagi nilai awalan momentum,  $\beta$  dan pemalar pembelajaran,  $\alpha$  akan ditentukan secara rawak. Contohnya nilai bagi setiap parameter  $\alpha$  dan  $\beta$  ditentukan dalam julat 0.1, 0.5, 0.9. Bagi kaedah untuk menentukan bilangan nod tersembunyi pula diberi seperti formula di dalam Jadual 3.5.

**Jadual 3.5** : Formula pengiraan nod tersembunyi dan pencadangnya.

<b>Formula</b>	<b>Dicadangkan oleh</b>
n	Tang dan Fishwrik, 1993
n/2	Kang, 1991
2n	Wong, 1991
2n+1	Lippman,1987 : Hecht-Neilsen, 1990

Langkah 6 : Memilih algoritma pembelajaran yang sesuai.

Di dalam kaedah rangkaian neural, terdapat banyak algoritma pembelajaran yang sesuai digunakan antaranya, Radial Basis, Botlzman, Rambatan ke Belakang, Perseptron, ART, BAM, DBD, DNNA, GRNN dan sebagainya. Di dalam projek ini, algoritma yang telah dipilih ialah pembelajaran secara seliaan (*supervised*) iaitu dengan menggunakan kaedah rambatan ke belakang. Persembahan aplikasi sesuatu data yang baik bergantung kepada kecekapan dan ketepatan hasil keputusan kerja yang dijalankan.

Langkah 7 : Memilih kaedah untuk menilai prestasi rangkaian.

RMS, MAPE dan MSE merupakan antara contoh kaedah yang boleh digunakan untuk menilai prestasi rangkaian. Untuk membangunkan model ramalan taburan hujan ini, MSE (Min Ralat Punca Kuasa Dua) akan digunakan. MSE melakukan penjumlahan kuasa dua ralat bagi setiap elemen pemproses dan kemudian dibahagikan dengan jumlah bilangan elemen dalam aras output untuk mendapatkan nilai puratanya kemudian diambil nilai punca kuasa dua bagi purata tersebut.

Langkah 8 : Melatih rangkaian

Rangkaian akan diperhatikan semasa proses pembelajaran atau latihan dan rangkaian yang berjaya menghasilkan nilai MSE yang paling kecil akan dipilih. Kemudian, model tersebut akan diuji sehingga memenuhi kriteria yang diperlukan dengan mengubah nilai pada pemberat yang digunakan. Semasa rangkaian sedang dilatih, MSE semakin lama semakin menurun sehingga menghampiri nilai sasaran yang ditentukan. Nilai sasaran yang ditetapkan adalah hampir dengan sifar, iaitu 0.01. Walau bagaimanapun, terdapat juga beberapa stesen yang menggunakan nilai sasaran 0.02, 0.3 atau 0.05. Nilai sasaran ini tidak ditetapkan dengan sifar kerana rangkaian akan mengambil masa yang lama untuk menyudahkan sesuatu latihan yang sempurna. Semakin banyak lelaran latihan dalam rangkaian, semakin menghampiri nilai output yang dikehendaki. Proses pembelajaran memerlukan set data yang banyak, ini kerana semakin banyak set data, maka kejituan rangkaian semakin menaik.

Langkah 9 : Menggunakan rangkaian

Bagi rangkaian yang menghasilkan nilai ralat yang kecil akan dipilih bagi mewakili model peramalan yang akan dibangunkan. Oleh itu, rangkaian yang dibina boleh menghasilkan output seperti yang dikehendaki berdasarkan input yang diberikan.

## **BAB 4**

### **REKABENTUK MODEL PERAMALAN BOX-JENKINS**

#### **4.1 Pengenalan**

Proses peramalan hanya boleh dilakukan setelah model yang bersesuaian dengan corak aliran data sedia ada diperolehi terlebih dahulu. Untuk membuat penentuan terhadap model peramalan yang sesuai, aspek-aspek yang perlu diambilkira:

- i) Kepegunan data.  
Aliran data perlulah dipegunkan terlebih dahulu dengan melakukan pembezaan terhadap data-data tersebut sekiranya data-data yang sedia ada tidak memiliki sifat-sifat kepegunan.
- ii) Ujian hipotesis t ke atas parameter dan pemalar terlibat.
- iii) Ujian statistik Ljung-Box bagi menguji kesesuaian model yang telah dipilih.

Pada peringkat awal penentuan model yang bersesuaian, jenis model-model yang mungkin bagi setiap stesen disenaraikan:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

- *Peringkat (1,3):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3}$$

- *Peringkat (2,1):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

- *Peringkat (2,3):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3}$$

- *Peringkat (3,1):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

- *Peringkat (3,3):*

$$Z_t = \delta + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3}$$

## 4.2 Penentuan Model Peramalan Bagi Daerah Batu Pahat

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal BATU PAHAT(BP) terhadap masa, graf ACF BP, dan graf PACF BP pada Rajah 4.1. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal BP untuk menghasilkan set data BATU PAHAT dengan pembezaan peringkat kedua (BP D(-1)(-1)).

Seterusnya pemerhatian dibuat terhadap graf BP D(-1)(-1), graf ACF BP D(-1)(-1), dan graf PACF BP D(-1)(-1) pada Rajah 4.2. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan BP. Pemerhatian terhadap graf ACF mendapati penggalan wujud pada selang pertama manakala untuk graf PACF, penggalan wujud pada selang kelima. Oleh itu, sukar untuk membuat anggaran yang sesuai untuk model peramalan yang sesuai. Seterusnya, set data BP D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.584027 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.768526 Z_{t-1} - 0.387279 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.904763 Z_{t-1} - 0.643746 Z_{t-2} - 0.389315 Z_{t-3} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.932017 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 1.301313 \varepsilon_{t-1} + 0.379013 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 1.376206 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + 0.315995 \varepsilon_{t-3}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = \varepsilon_t - 0.911207 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = -0.880751 Z_{t-1} + \varepsilon_t - 0.701476 \varepsilon_{t-2}$$

- *Peringkat (1,3):*

$$Z_t = -0.876312 Z_{t-1} + \varepsilon_t$$

- *Peringkat (2,1):*

$$Z_t = -0.281585 Z_{t-1} + \varepsilon_t - 0.893996 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = 0.508219 Z_{t-1} + \Phi_2 Z_{t-2} + \varepsilon_t - 1.812672 \varepsilon_{t-1} - 0.904407 \varepsilon_{t-2}$$

- *Peringkat (2,3):*

$$Z_t = 0.461295 Z_{t-2} + \varepsilon_t - 0.9767 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + 0.0757517 \varepsilon_{t-3}$$

- *Peringkat (3,1):*

$$Z_t = -0.349328 Z_{t-1} + \varepsilon_t - 0.861842 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = 0.475208 Z_{t-1} + \Phi_2 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t - 1.800928 \varepsilon_{t-1} + 0.901158 \varepsilon_{t-2}$$

- *Peringkat (3,3):*

$$Z_t = 0.363007 Z_{t-2} + \Phi_3 Z_{t-3} + \varepsilon_t - 1.047674 \varepsilon_{t-1} + 0.690575 \varepsilon_{t-3}$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

ii) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran E. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.584027 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.768526 Z_{t-1} - 0.387279 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*



$$Z_t = -0.904763 Z_{t-1} - 0.643746 Z_{t-2} - 0.389315 Z_{t-3} + \varepsilon_t$$

Model Purata Bergerak (MA):


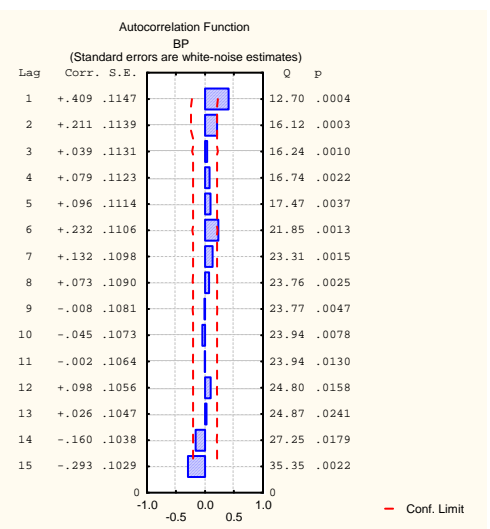

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.932017 \varepsilon_{t-1}$$

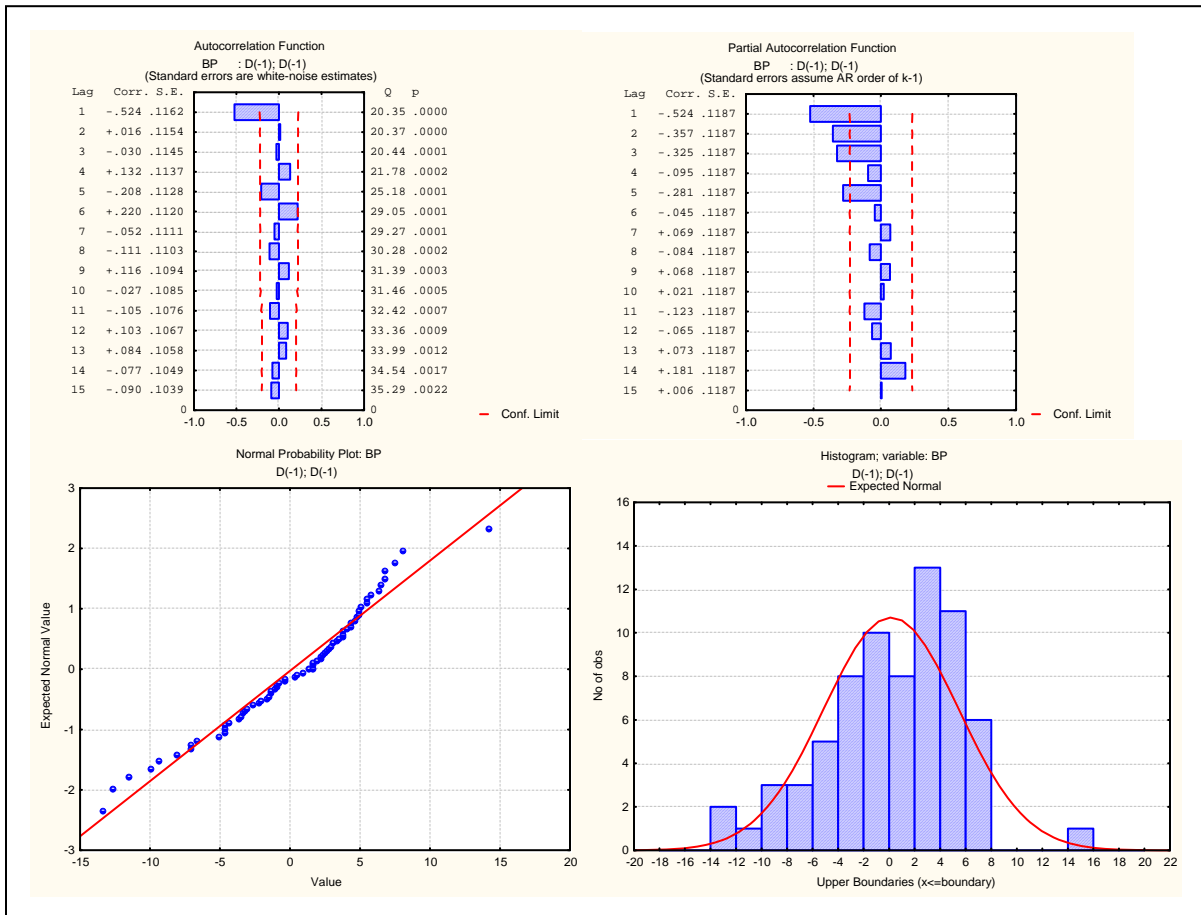
- *Peringkat 2:*

$$Z_t = \varepsilon_t - 1.301313 \varepsilon_{t-1} + 0.379013 \varepsilon_{t-2}$$

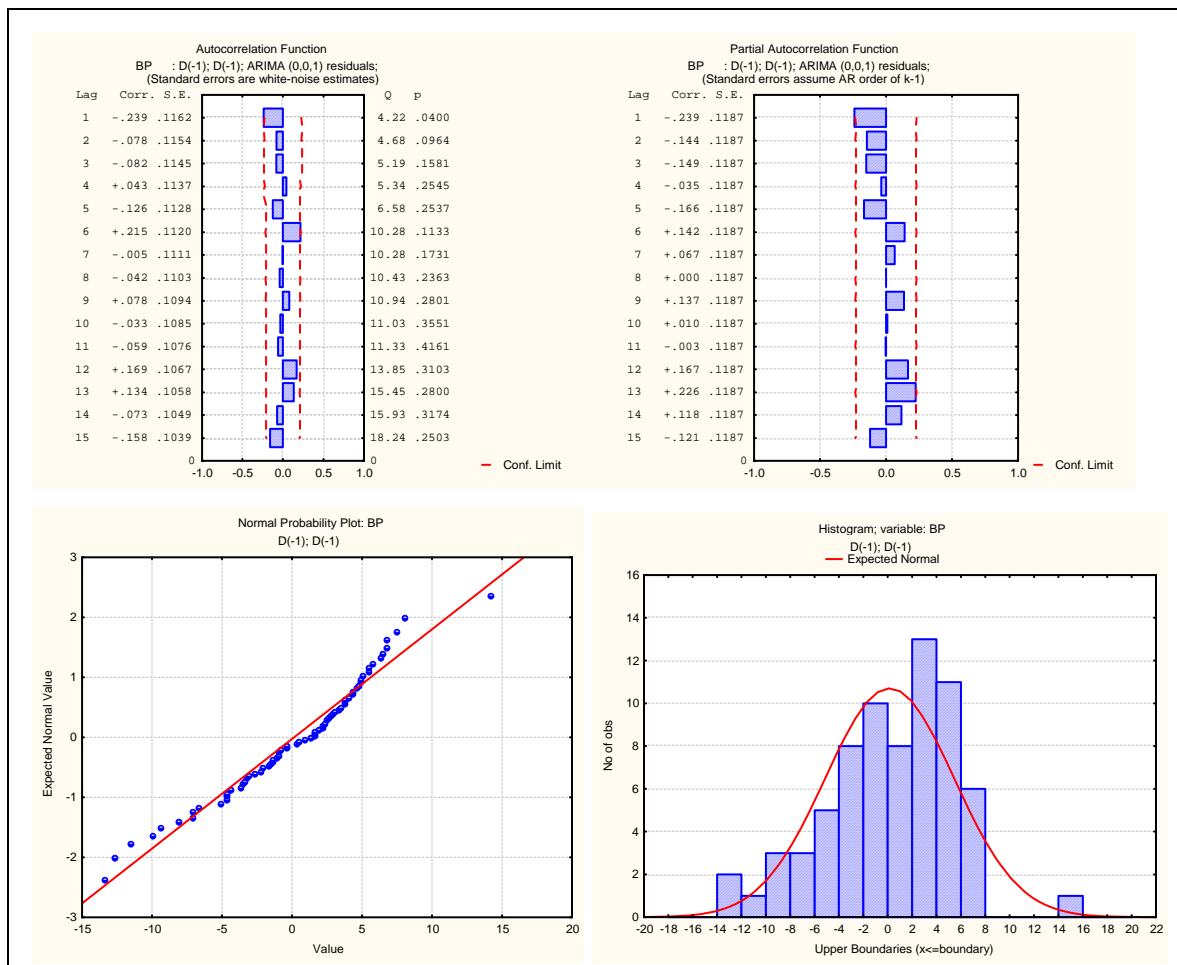
Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai MSE setiap model seperti yang terkandung dalam Lampiran E dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model ARMA peringkat (0,1) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(0,1) dipilih sebagai model untuk BATU PAHAT. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.3.



Rajah 4.1



Rajah 4.2



Rajah 4.3

### 4.3. Penentuan Model Peramalan Bagi Daerah Johor Bahru

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal JOHOR BAHRU (JB) terhadap masa, graf ACF JB, dan graf PACF JB pada Rajah 4.4.. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal JB untuk menghasilkan set data JB dengan pembezaan peringkat pertama (JB D(-1)).

Seterusnya pemerhatian dibuat terhadap graf JB D(-1), graf ACF JB D(-1), dan garf PACF JB D(-1) pada Rajah 4.5.. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan JB. Pemerhatian terhadap graf ACF dan PACF mendapati kedua-duanya semakin menyusut dalam gelombang sinus. Oleh itu, boleh dianggarkan bahawa model yang akan sesuai untuk set data JB D(-1) ialah Model ARMA. Seterusnya, set data JB D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2..

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.403713 \varepsilon_{t-1} - 0.304922 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.331158 \varepsilon_{t-1} - 0.251371 \varepsilon_{t-3}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = 0.551543 Z_{t-1} + \varepsilon_t - 0.910190 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = 0.481487 Z_{t-1} + \varepsilon_t - 0.817250 \varepsilon_{t-1}$$

- *Peringkat (1,3):*

$$Z_t = \varepsilon_t$$

- *Peringkat (2,1):*

$$Z_t = -0.574503 Z_{t-1} + \varepsilon_t - 0.899048 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = \varepsilon_t$$

- *Peringkat (2,3):*

$$Z_t = \varepsilon_t$$

- *Peringkat (3,1):*

$$Z_t = 0.523113 Z_{t-1} \varepsilon_t - 0.862099 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = \varepsilon_t$$

- *Peringkat (3,3):*

$$Z_t = \varepsilon_t$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

iii) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran F. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Purata Bergerak (MA):

- *Peringkat 2:*

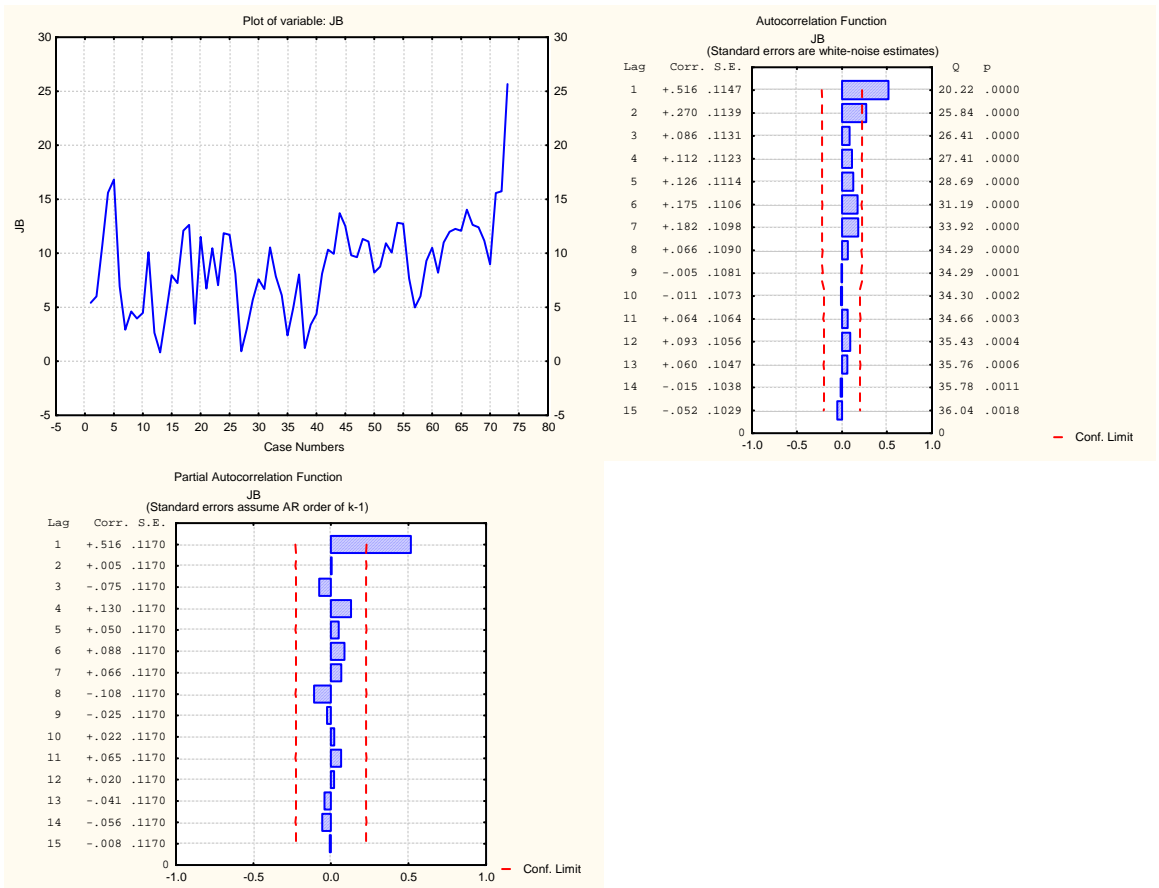
$$Z_t = \varepsilon_t - 0.403713 \varepsilon_{t-1} - 0.304922 \varepsilon_{t-2}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

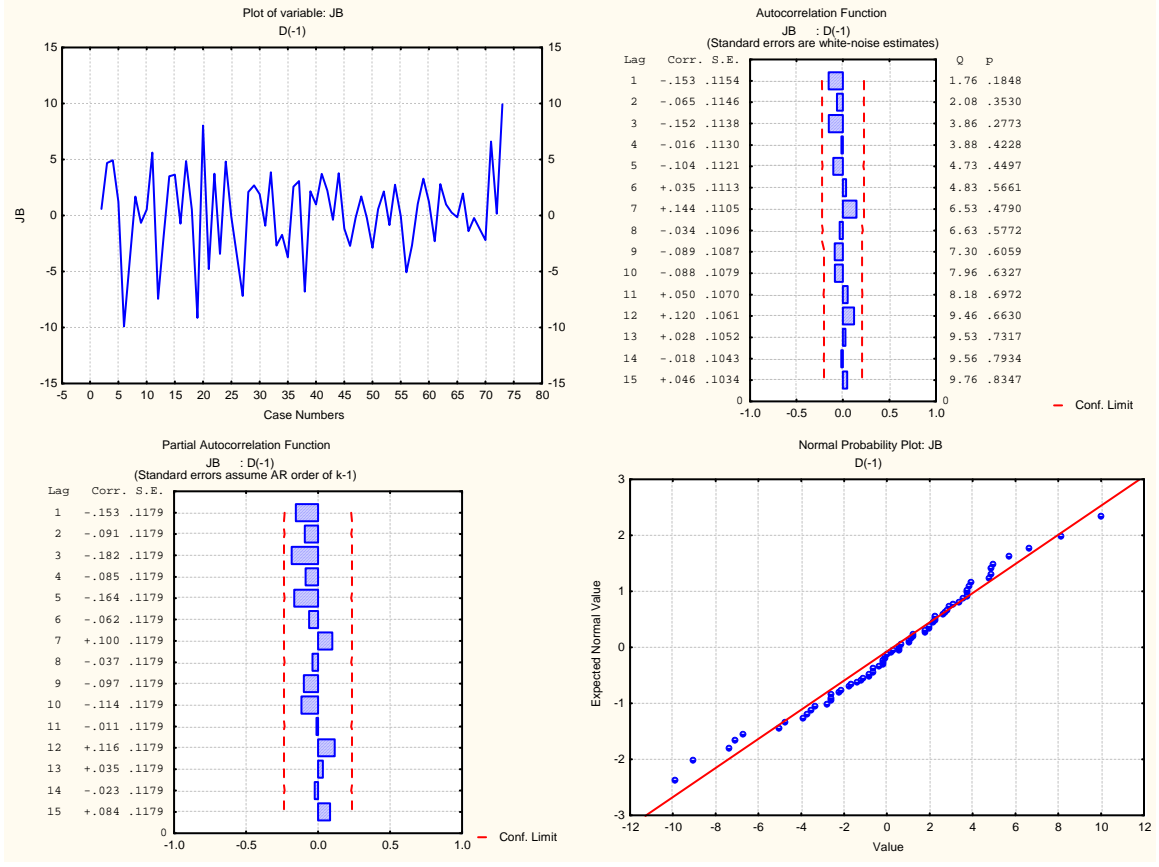
$$Z_t = 0.551543 Z_{t-1} + \varepsilon_t - 0.910190 \varepsilon_{t-1}$$

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai MSE setiap model seperti yang terkandung dalam Lampiran F dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model ARMA peringkat (1,1) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(1,1) dipilih sebagai model untuk JOHOR BAHRU. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.6.

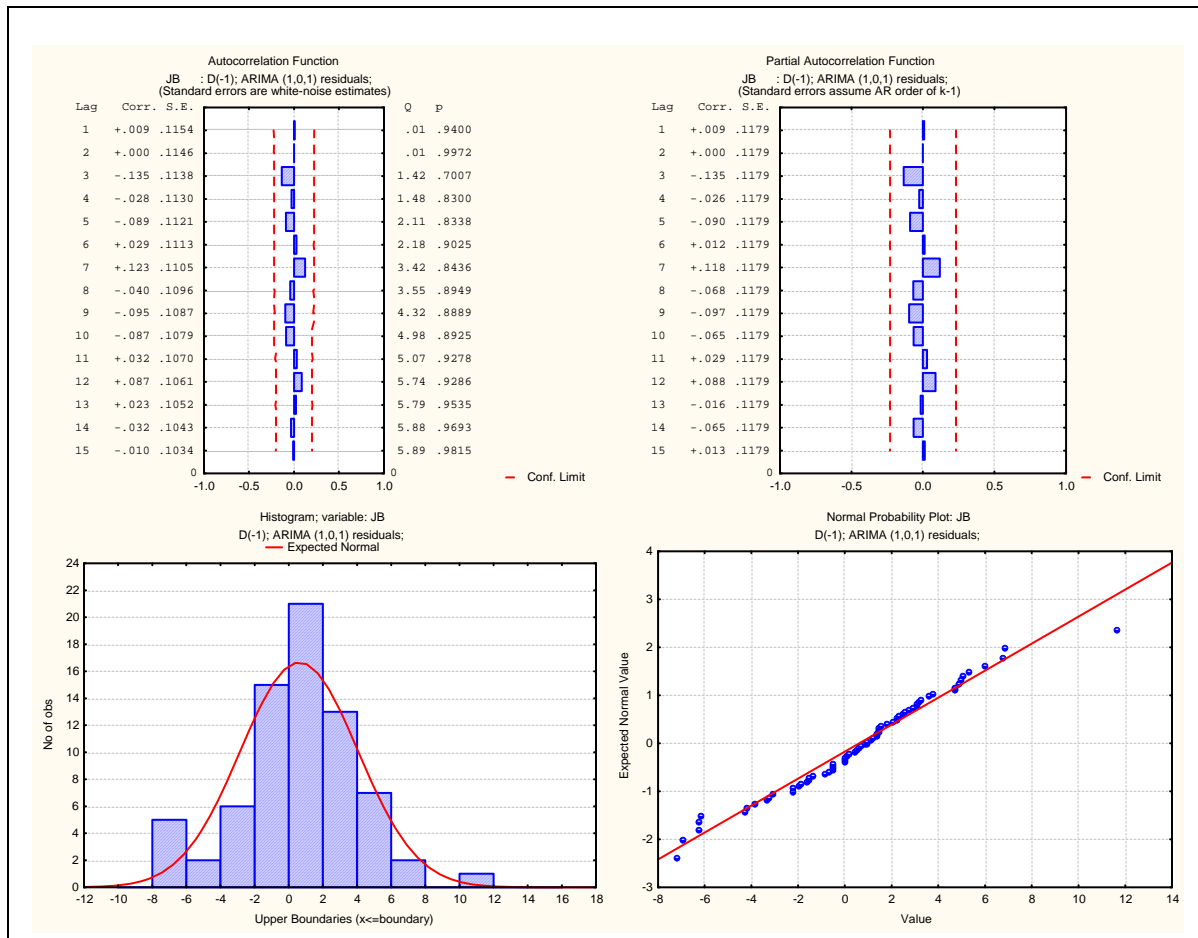


Rajah 4.4





Rajah 4.5



Rajah 4.6

#### 4.4 Penentuan Model Peramalan Bagi Daerah Kluang

Kepegunanan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal KLUANG A (KLUANGA) terhadap masa, graf ACF KLUANGA, dan graf PACF KLUANGA pada Rajah 4.7.. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal KLUANGA untuk menghasilkan set data KLUANGA dengan pembezaan peringkat pertama (KLUANGA D(-1)).

Seterusnya pemerhatian dibuat terhadap graf KLUANGA D(-1), graf ACF KLUANGA D(-1), dan garf PACF KLUANGA D(-1) pada Rajah 4.8.. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan KLUANGA. Pemerhatian terhadap graf ACF mendapati penggalan wujud pada selang pertama manakala untuk graf PACF, penggalan wujud pada selang keempat. Oleh itu, sukar untuk membuat anggaran yang sesuai untuk model peramalan yang sesuai. Seterusnya, set data KLUANGA D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2..

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.257254 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.31127 Z_{t-1} - 0.250404 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.371509 Z_{t-1} - 0.300187 Z_{t-2} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.749046 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.519803 \varepsilon_{t-1} - 0.289073 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.510247 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = 0.342399 Z_{t-1} + \varepsilon_t - 0.881998 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = \varepsilon_t$$

- *Peringkat (1,3):*

$$Z_t = \varepsilon_t$$

- *Peringkat (2,1):*

$$Z_t = 0.346688 Z_{t-1} + \varepsilon_t - 0.852505 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = 0.783180 Z_{t-1} + \varepsilon_t - 1.291884 \varepsilon_{t-1}$$

- *Peringkat (2,3):*

$$Z_t = \varepsilon_t$$

- *Peringkat (3,1):*

$$Z_t = \varepsilon_t - 0.804028 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = \varepsilon_t - 1.081391 \varepsilon_{t-1}$$

- *Peringkat (3,3):*

$$Z_t = 1.60056 Z_{t-1} - 1.42153 Z_{t-2} + \varepsilon_t - 2.16088 \varepsilon_{t-1} + 2.04966 \varepsilon_{t-2} - 0.79759 \varepsilon_{t-3}$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

iv) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran G. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.257254 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.31127 Z_{t-1} - 0.250404 Z_{t-2} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.749046 \varepsilon_{t-1}$$

- *Peringkat 2:*


$$Z_t = \varepsilon_t - 0.519803 \varepsilon_{t-1} - 0.289073 \varepsilon_{t-2}$$

Model Autoregresif Purata Bergerak (ARMA):

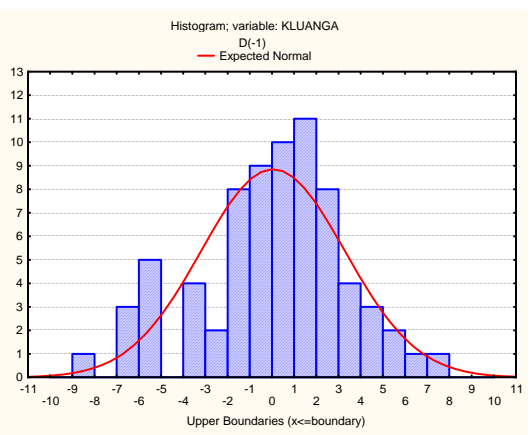


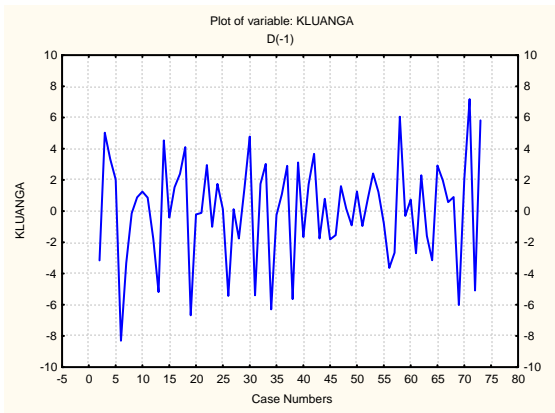
- *Peringkat (1,1):*

$$Z_t = 0.342399 Z_{t-1} + \varepsilon_t - 0.881998 \varepsilon_{t-1}$$

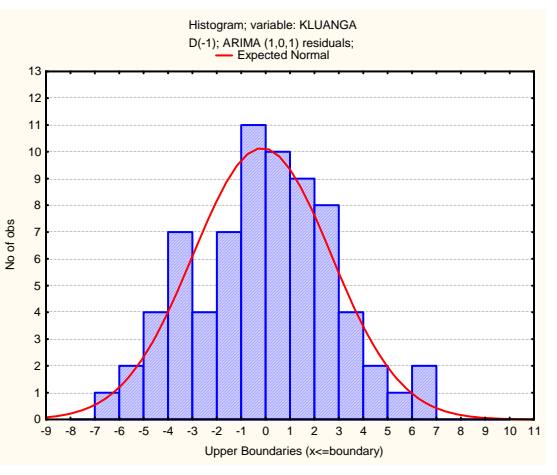
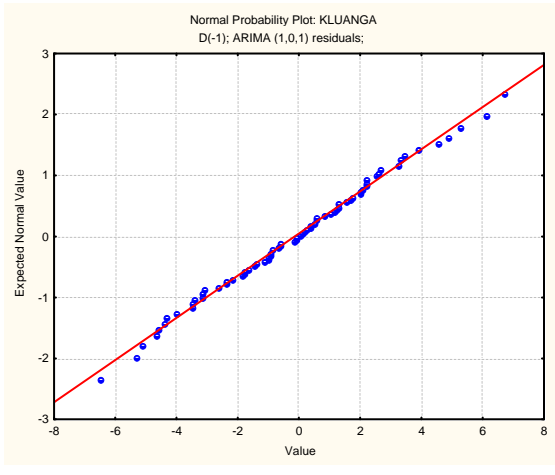
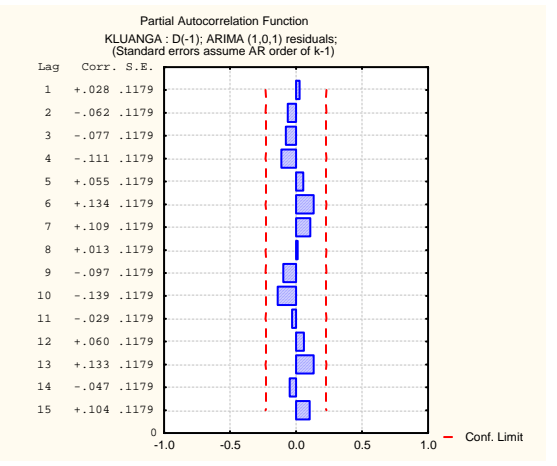

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran G dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model MA peringkat (2) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model MA(2) dipilih sebagai model untuk KLUANG A. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.9.



Rajah 4.7



Rajah 4.8



Rajah 4.9



#### 4.5 Penentuan Model Peramalan Bagi Daerah Kota Tinggi

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal KOTA TINGGI (KOTA) terhadap masa, graf ACF KOTA, dan graf PACF KOTA pada Rajah 4.10.. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal KOTA untuk menghasilkan set data KOTA dengan pembezaan peringkat pertama (KOTA D(-1)).

Seterusnya pemerhatian dibuat terhadap graf KOTA D(-1), graf ACF KOTA D(-1), dan garf PACF KOTA D(-1) pada Rajah 4.11. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan KOTA. Pemerhatian terhadap graf ACF dan PACF mendapati kedua-duanya terpenggal pada susulan pertama. Seterusnya, set data KLUANGB D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*  
$$Z_t = -0.463188 Z_{t-1} + \varepsilon_t$$
- *Peringkat 2:*  
$$Z_t = -0.467503 Z_{t-1} + \varepsilon_t$$
- *Peringkat 3:*  
$$Z_t = -0.489751 Z_{t-1} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*  
$$Z_t = \varepsilon_t - 0.526120 \varepsilon_{t-1}$$
- *Peringkat 2:*  
$$Z_t = \varepsilon_t - 0.526607 \varepsilon_{t-1}$$
- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.567274 \varepsilon_{t-1} - 0.416784 \varepsilon_{t-3}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = \varepsilon_t - 0.831884 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = -0.692106 Z_{t-1} + \varepsilon_t$$

- *Peringkat (1,3):*

$$Z_t = \varepsilon_t - 0.470132 \varepsilon_{t-3}$$

- *Peringkat (2,1):*

$$Z_t = 0.392499 Z_{t-1} + 0.306992 Z_{t-2} + \varepsilon_t - 0.9998877 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = 0.474798 Z_{t-2} + \varepsilon_t$$

- *Peringkat (2,3):*

$$Z_t = \varepsilon_t$$

- *Peringkat (3,1):*

$$Z_t = 0.318136 Z_{t-2} + \varepsilon_t - 0.908830 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = \varepsilon_t - 0.925201 \varepsilon_{t-1}$$

- *Peringkat (3,3):*

$$Z_t = \varepsilon_t - 0.777712 \varepsilon_{t-3}$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(w/2)}$$

ii) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran H dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.463188 Z_{t-1} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*


$$Z_t = \varepsilon_t - 0.526120 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

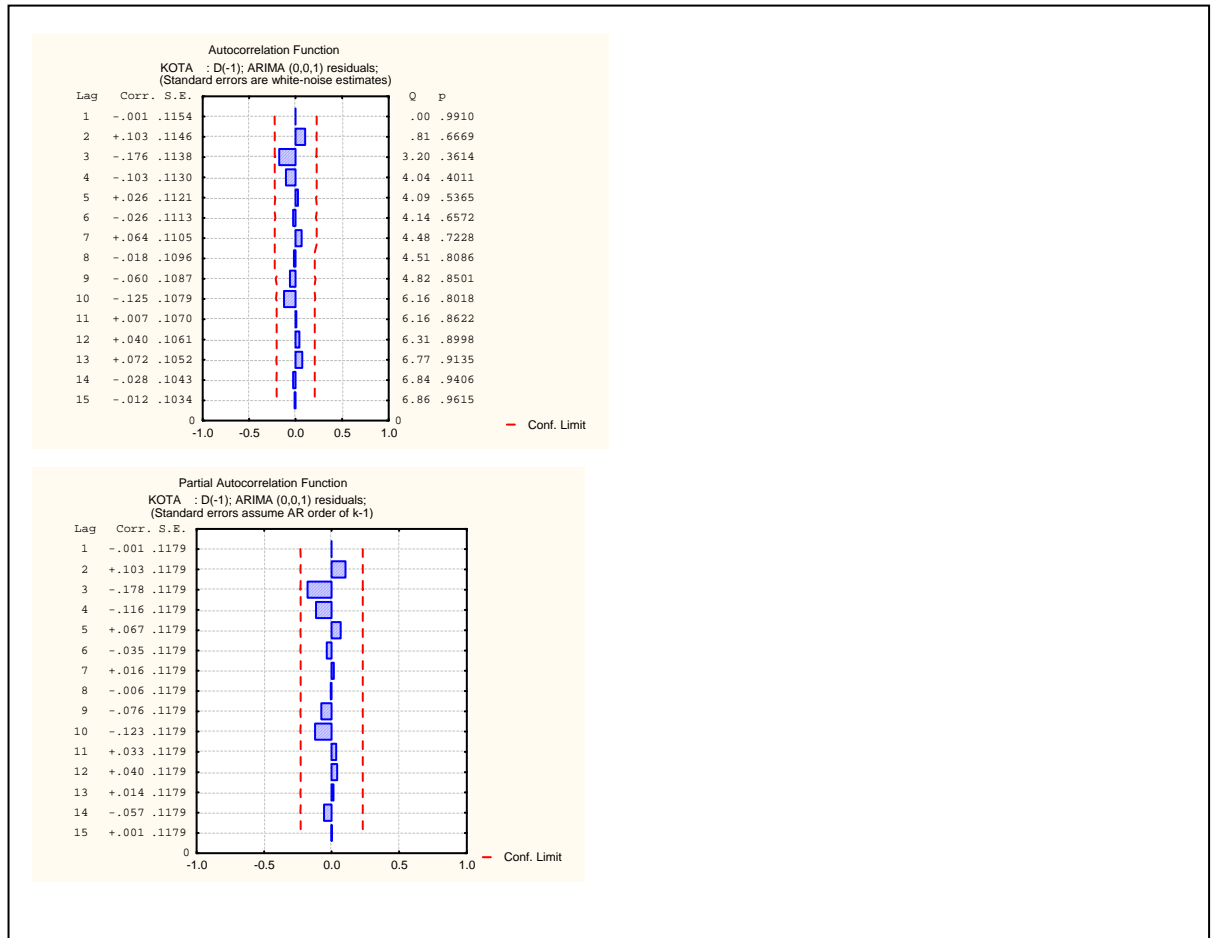
- *Peringkat (2,1):*

$$Z_t = 0.392499 Z_{t-1} + 0.306992 Z_{t-2} + \varepsilon_t - 0.9998877 \varepsilon_{t-1}$$

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran H. Hasil perbandingan tersebut, model ARMA peringkat (2,1) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(2,1) dipilih sebagai model untuk KOTA. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.12.



Rajah 4.11



Rajah 4.12

#### 4.6 Penentuan Model Peramalan Bagi Daerah Mersing

Kepegunanan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal MERSING terhadap masa, graf ACF MERSING, dan graf PACF MERSING pada Rajah 4.13. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal MERSING untuk menghasilkan set data MERSING dengan pembezaan peringkat pertama (MERSING D(-1)).

Seterusnya pemerhatian dibuat terhadap graf MERSING D(-1), graf ACF MERSING D(-1), dan garf PACF MERSING D(-1) pada Rajah 4.14. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan MERSING. Pemerhatian terhadap graf ACF dan PACF mendapati kedua-duanya mempunyai corak yang agak sukar untuk ditentukan. Seterusnya, set data MERSING D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.292398 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.325441 Z_{t-1} - 0.342243 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.349403 Z_{t-1} - 0.404546 Z_{t-2} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.591576 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.416541 \varepsilon_{t-1} - 0.390041 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.415555 \varepsilon_{t-1} - 0.388779 \varepsilon_{t-2}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = 0.425515 Z_{t-1} + \varepsilon_t - 0.901751 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = \varepsilon_t - 0.766764 \varepsilon_{t-1}$$

- *Peringkat (1,3):*

$$Z_t = 0.817777 Z_{t-1} + \varepsilon_t - 1.250466 \varepsilon_{t-1} + 0.366030 \varepsilon_{t-3}$$

- *Peringkat (2,1):*  

$$Z_t = 0.42547 Z_{t-1} + \varepsilon_t - 0.838594 \varepsilon_{t-1}$$
- *Peringkat (2,2):*  

$$Z_t = \varepsilon_t$$
- *Peringkat (2,3):*  

$$Z_t = 0.971945 Z_{t-1} + \varepsilon_t - 1.392192 \varepsilon_{t-1}$$
- *Peringkat (3,1):*  

$$Z_t = 0.397538 Z_{t-1} + \varepsilon_t - 0.815349 \varepsilon_{t-1}$$
- *Peringkat (3,2):*  

$$Z_t = \varepsilon_t$$
- *Peringkat (3,3):*  

$$Z_t = \varepsilon_t$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

iii) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran I. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*  

$$Z_t = -0.292398 Z_{t-1} + \varepsilon_t$$
- *Peringkat 2:*  

$$Z_t = -0.325441 Z_{t-1} - 0.342243 Z_{t-2} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.591576 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.416541 \varepsilon_{t-1} - 0.390041 \varepsilon_{t-2}$$

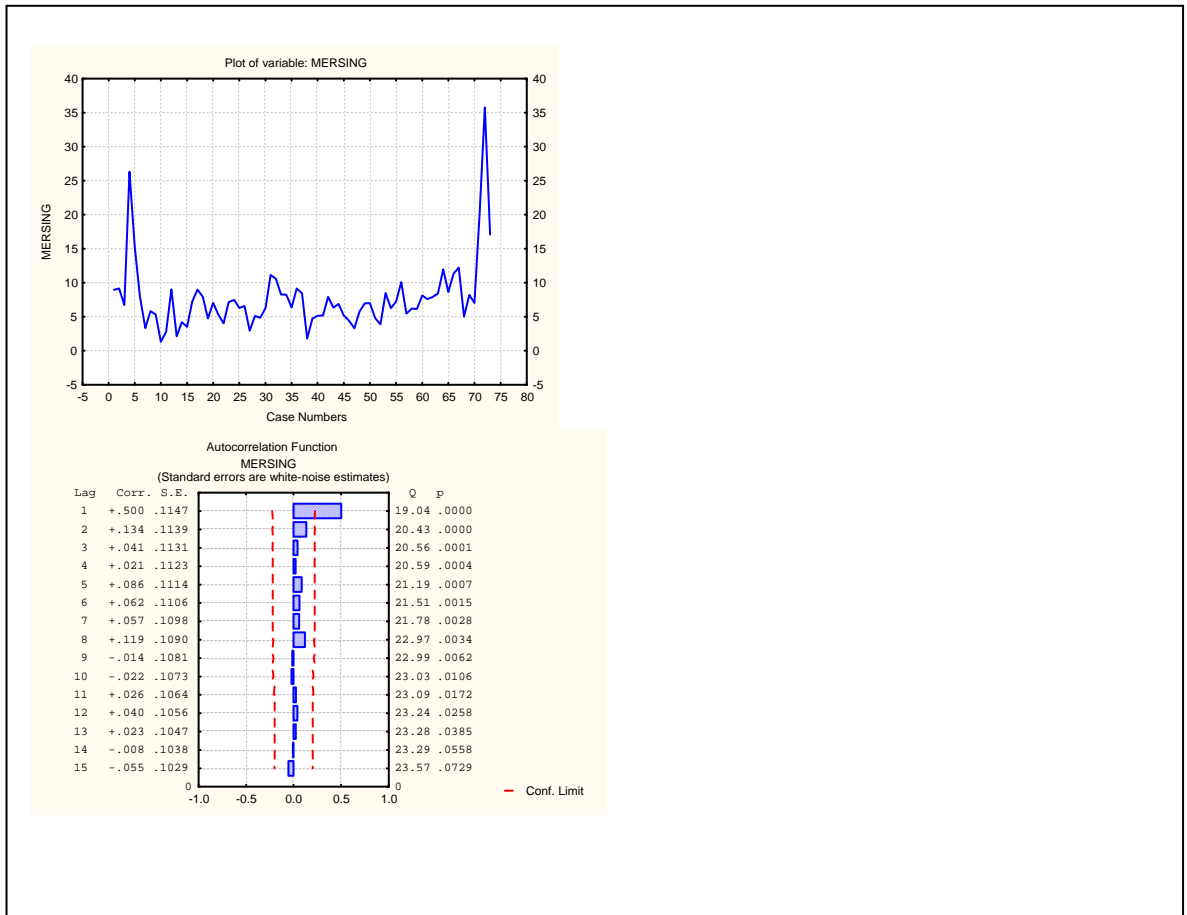
Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

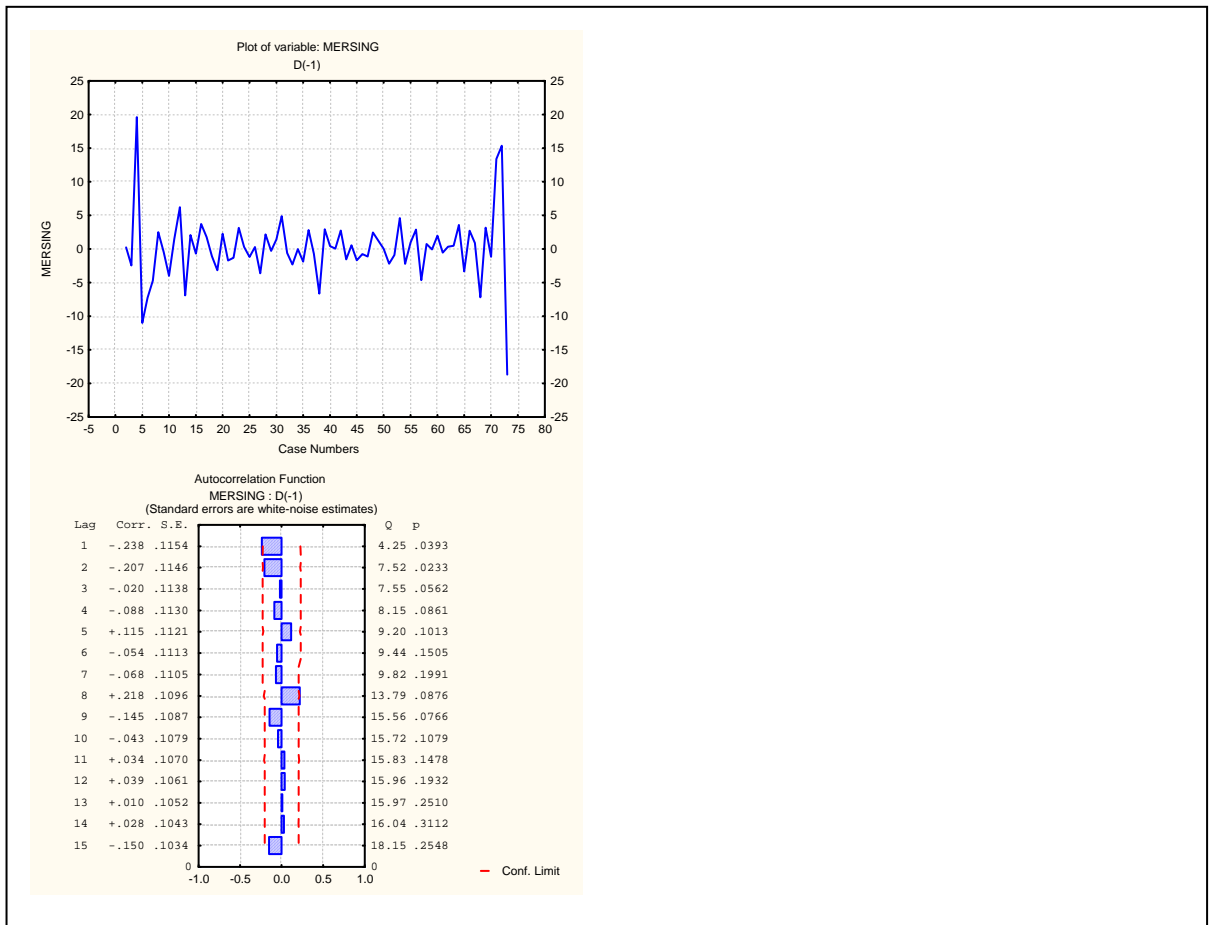
$$Z_t = 0.425515 Z_{t-1} + \varepsilon_t - 0.901751 \varepsilon_{t-1}$$

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran I dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model MA peringkat (2) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model MA(2) dipilih sebagai model untuk MERSING. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.15.

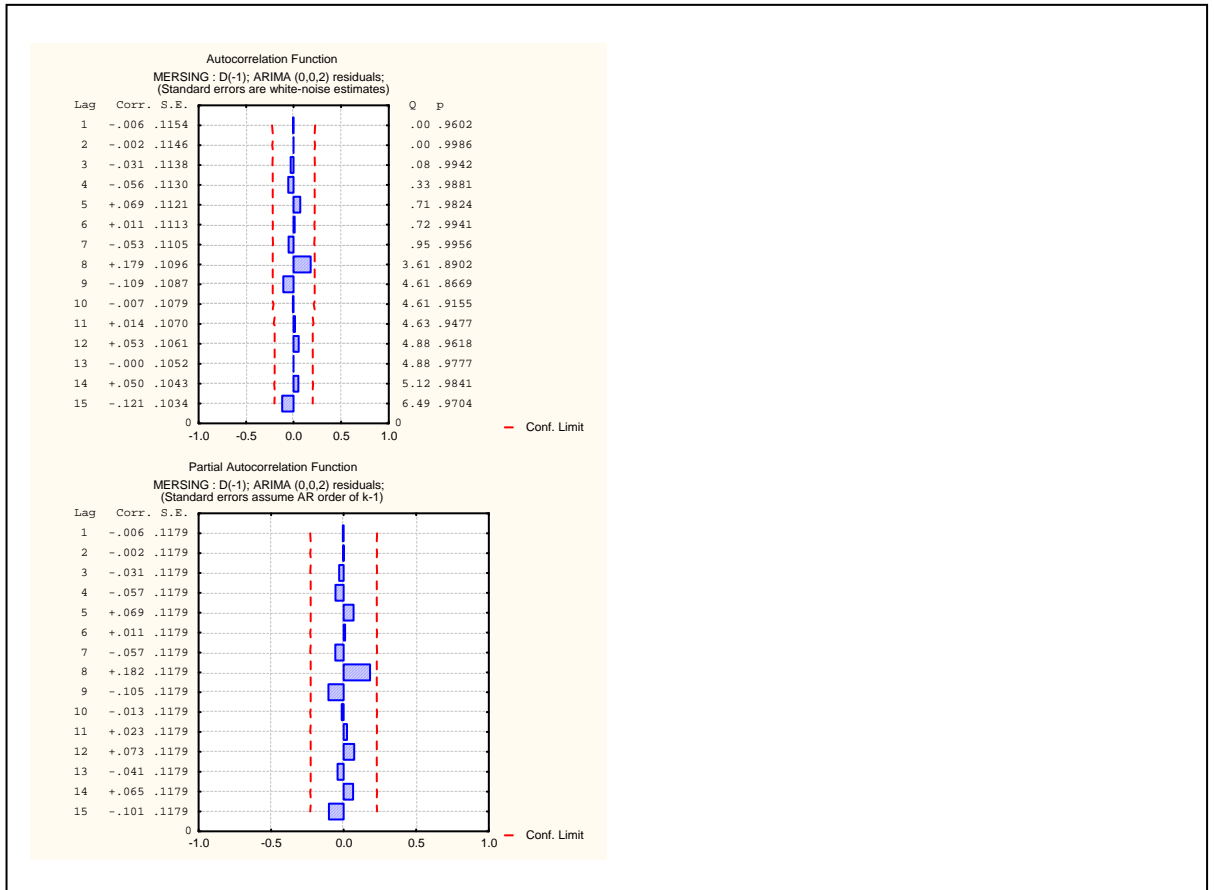




Rajah 4.13



Rajah 4.14



Rajah 4.15

#### 4.7 Penentuan Model Peramalan Bagi Daerah Muar

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal MUAR A(MUARA) terhadap masa, graf ACF MUARA, dan graf PACF MUARA pada Rajah 4.16.. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal MUARA untuk menghasilkan set data MUARA dengan pembezaan peringkat pertama (MUARA D(-1)).

Seterusnya pemerhatian dibuat terhadap graf MUARA D(-1), graf ACF MUARA D(-1), dan garf PACF MUARA D(-1) pada Rajah 4.17. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan MUARA. Pemerhatian terhadap graf ACF mendapati penggalan wujud pada selang pertama manakala untuk graf PACF, penggalan wujud pada selang kedua. Seterusnya, set data MUARA D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.461221 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.558261 Z_{t-1} - 0.273424 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.552994 Z_{t-1} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.689086 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.646083 \varepsilon_{t-1}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.693174 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = \varepsilon_t - 0.792753 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = \varepsilon_t - 1.208606 \varepsilon_{t-1}$$

- *Peringkat (1,3):*  

$$Z_t = \varepsilon_t - 1.03256 \varepsilon_{t-1}$$
- *Peringkat (2,1):*  

$$Z_t = \varepsilon_t - 0.847735 \varepsilon_{t-1}$$
- *Peringkat (2,2):*  

$$Z_t = \varepsilon_t$$
- *Peringkat (2,3):*  

$$Z_t = 0.51098 Z_{t-1} - 0.73353 Z_{t-2} + \varepsilon_t - 1.22622 \varepsilon_{t-1} + 1.29623 \varepsilon_{t-2} - 0.75949 \varepsilon_{t-3}$$
- *Peringkat (3,1):*  

$$Z_t = \varepsilon_t - 0.870203 \varepsilon_{t-1}$$
- *Peringkat (3,2):*  

$$Z_t = -0.735845 Z_{t-1} + \varepsilon_t + 0.118383 \varepsilon_{t-1} - 0.881322 \varepsilon_{t-2}$$
- *Peringkat (3,3):*  

$$Z_t = -0.478323 Z_{t-1} - 0.691240 Z_{t-2} + \varepsilon_t + 0.334621 \varepsilon_{t-1} - 0.776066 \varepsilon_{t-3}$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

v) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran J. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.461221 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.558261 Z_{t-1} - 0.273424 Z_{t-2} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*


$$Z_t = \varepsilon_t - 0.689086 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

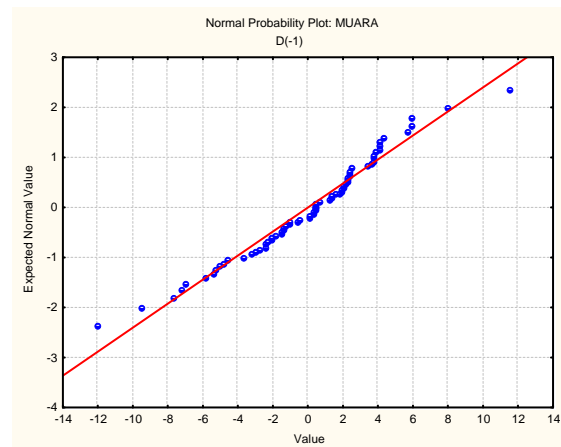


- *Peringkat (2,3):*

$$Z_t = 0.51098 Z_{t-1} - 0.73353 Z_{t-2} + \varepsilon_t - 1.22622 \varepsilon_{t-1} + 1.29623 \varepsilon_{t-2} - 0.75949 \varepsilon_{t-3}$$

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran J dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model ARMA peringkat (2,3) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(2,3) dipilih sebagai model untuk MUAR A. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.18.




Rajah 4.16



Rajah 4.17





Rajah 4.18

#### 4.8 Penentuan Model Peramalan Bagi Daerah Pontian

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal PONTIAN terhadap masa, graf ACF PONTIAN, dan graf PACF PONTIAN pada Rajah 4.19.. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan

dibuat terhadap set data asal PONTIAN untuk menghasilkan set data PONTIAN dengan pembezaan peringkat pertama (PONTIAN D(-1)).

Seterusnya pemerhatian dibuat terhadap graf PONTIAN D(-1), graf ACF PONTIAN D(-1), dan graf PACF PONTIAN D(-1) pada Rajah 4.20. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan PONTIAN. Pemerhatian terhadap graf ACF dan PACF mendapati kedua-duanya menyusut secara gelombang sinus. Oleh itu, anggaran awal menjangkakan model peramalan yang akan dijana adalah berbentuk ARMA. Seterusnya, set data PONTIAN D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*  
$$Z_t = -0.271763 Z_{t-1} + \varepsilon_t$$
- *Peringkat 2:*  
$$Z_t = -0.314473 Z_{t-1} + \varepsilon_t$$
- *Peringkat 3:*  
$$Z_t = -0.358711 Z_{t-1} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*  
$$Z_t = \varepsilon_t - 0.558238 \varepsilon_{t-1}$$
- *Peringkat 2:*  
$$Z_t = \varepsilon_t - 0.471990 \varepsilon_{t-1}$$
- *Peringkat 3:*  
$$Z_t = \varepsilon_t - 0.471202 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*  
$$Z_t = 0.413542 Z_{t-1} + \varepsilon_t - 0.878986 \varepsilon_{t-1}$$
- *Peringkat (1,2):*  
$$Z_t = \varepsilon_t$$

- *Peringkat (1,3):*  
 $Z_t = \varepsilon_t$
- *Peringkat (2,1):*  
 $Z_t = 0.413754 Z_{t-1} + \varepsilon_t - 0.872904 \varepsilon_{t-1}$
- *Peringkat (2,2):*  
 $Z_t = \varepsilon_t$
- *Peringkat (2,3):*  
 $Z_t = \varepsilon_t$
- *Peringkat (3,1):*  
 $Z_t = \varepsilon_t - 0.863905 \varepsilon_{t-1}$
- *Peringkat (3,2):*  
 $Z_t = \varepsilon_t$
- *Peringkat (3,3):*  
 $Z_t = \varepsilon_t$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

iv) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran K. Parameter-parameter yang melepasi ujian-ujian tersebut digelapkan. Model-model yang melepasi ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*  
 $Z_t = -0.271763 Z_{t-1} + \varepsilon_t$

Model Purata Bergerak (MA):

- *Peringkat 1:*


$$Z_t = \varepsilon_t - 0.558238 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):


- *Peringkat (1,1):*

$$Z_t = 0.413542 Z_{t-1} + \varepsilon_t - 0.878986 \varepsilon_{t-1}$$


Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran K dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model ARMA peringkat (1,1) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(1,1) dipilih sebagai model untuk PONTIAN. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.21.



Rajah 4.19



Rajah 4.20



Rajah 4.21

#### 4.9 Penentuan Model Peramalan Bagi Daerah Segamat

Kepegunungan data boleh diperolehi setelah transformasi pembezaan peringkat pertama dilakukan terhadap set data ini. Pemerhatian dibuat terhadap graf set data asal SEGAMAT terhadap masa, graf ACF SEGAMAT, dan graf PACF SEGAMAT pada Rajah 4.22. Hasil pemerhatian mendapati data adalah tidak pegun kerana corak untuk set data asal tidak bergerak pada satu nilai tetap  $\mu$ . Oleh sebab itu, pembezaan dibuat terhadap set data asal SEGAMAT untuk menghasilkan set data SEGAMAT dengan pembezaan peringkat pertama (SEGAMAT D(-1)).

Seterusnya pemerhatian dibuat terhadap graf SEGAMAT D(-1), graf ACF SEGAMAT D(-1), dan graf PACF SEGAMAT D(-1) pada Rajah 4.23. Pemerhatian terhadap ketiga-tiga graf mendapati graf adalah cukup pegun untuk model-model yang sesuai ditentukan bagi peramalan PONTIAN. Pemerhatian terhadap graf ACF dan PACF mendapati kedua-duanya mempunyai bentuk yang sukar untuk ditakrifkan. Seterusnya, set data SEGAMAT D(-1) diuji dengan beberapa set-set model peramalan seperti yang tersenarai dalam bahagian 4.2.

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.268091 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.333503 Z_{t-1} - 0.239972 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.406265 Z_{t-1} - 0.338034 Z_{t-2} - 0.345607 Z_{t-3} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.745969 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.549616 \varepsilon_{t-1} - 0.239897 \varepsilon_{t-2}$$

- *Peringkat 3:*

$$Z_t = \varepsilon_t - 0.514157 \varepsilon_{t-1}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = 0.306854 Z_{t-1} + \varepsilon_t - 0.863594 \varepsilon_{t-1}$$

- *Peringkat (1,2):*

$$Z_t = \varepsilon_t - 0.644492 \varepsilon_{t-1}$$

- *Peringkat (1,3):*



$$Z_t = -0.844430 Z_{t-1} + \varepsilon_t + 0.396499 \varepsilon_{t-1} - 0.636748 \varepsilon_{t-2} - 0.395481 \varepsilon_{t-3}$$

3

- *Peringkat (2,1):*

$$Z_t = \varepsilon_t - 0.810284 \varepsilon_{t-1}$$

- *Peringkat (2,2):*

$$Z_t = 0.915711 Z_{t-1} - 0.457995 Z_{t-2} + \varepsilon_t - 1.452590 \varepsilon_{t-1} + 0.630722 \varepsilon_{t-2}$$

2

- *Peringkat (2,3):*

$$Z_t = 1.03858 Z_{t-1} - 0.91956 Z_{t-2} + \varepsilon_t - 1.65445 \varepsilon_{t-1} + 1.40398 \varepsilon_{t-2} - 0.48850 \varepsilon_{t-3}$$

- *Peringkat (3,1):*

$$Z_t = \varepsilon_t - 0.670232 \varepsilon_{t-1}$$

- *Peringkat (3,2):*

$$Z_t = 0.33178 Z_{t-2} + \varepsilon_t - 1.082545 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

- *Peringkat (3,3):*

$$Z_t = -0.481432 Z_{t-3} + \varepsilon_t$$

Ujian hipotesis t dilakukan untuk menentukan sama ada parameter  $\phi_t$  dan  $\theta_t$  perlu dimasukkan ke dalam model tersebut ataupun tidak, di mana

$$H_0 : = 0$$

$$H_1 : \neq 0 \text{ di mana } \alpha = 0.05$$

$H_0$  akan ditolak sekiranya ujian berikut dipatuhi

$$i) \quad \left| t \right| > t^{(n-np)}_{(\alpha/2)}$$

v) Ujian kebarangkalian  $p < 0.05$  adalah benar

Parameter-parameter untuk model-model yang diuji adalah tersenarai dalam jadual-jadual di Lampiran L. Parameter-parameter yang melepasi ujian-ujian tersebut

digelapkan. Model-model yang melewati ujian penganggaran parameter adalah seperti di bawah:

Model Autoregresif (AR):

- *Peringkat 1:*

$$Z_t = -0.268091 Z_{t-1} + \varepsilon_t$$

- *Peringkat 2:*

$$Z_t = -0.333503 Z_{t-1} - 0.239972 Z_{t-2} + \varepsilon_t$$

- *Peringkat 3:*

$$Z_t = -0.406265 Z_{t-1} - 0.338034 Z_{t-2} - 0.345607 Z_{t-3} + \varepsilon_t$$

Model Purata Bergerak (MA):

- *Peringkat 1:*

$$Z_t = \varepsilon_t - 0.745969 \varepsilon_{t-1}$$

- *Peringkat 2:*

$$Z_t = \varepsilon_t - 0.549616 \varepsilon_{t-1} - 0.239897 \varepsilon_{t-2}$$

Model Autoregresif Purata Bergerak (ARMA):

- *Peringkat (1,1):*

$$Z_t = 0.306854 Z_{t-1} + \varepsilon_t - 0.863594 \varepsilon_{t-1}$$

- *Peringkat (1,3):*

$$Z_t = -0.844430 Z_{t-1} + \varepsilon_t + 0.396499 \varepsilon_{t-1} - 0.636748 \varepsilon_{t-2} - 0.395481 \varepsilon_{t-3}$$

3

- *Peringkat (2,2):*


$$Z_t = 0.915711 Z_{t-1} - 0.457995 Z_{t-2} + \varepsilon_t - 1.452590 \varepsilon_{t-1} + 0.630722 \varepsilon_{t-2}$$

2


- *Peringkat (2,3):*

$$Z_t = 1.03858 Z_{t-1} - 0.91956 Z_{t-2} + \varepsilon_t - 1.65445 \varepsilon_{t-1} + 1.40398 \varepsilon_{t-2} - 0.48850 \varepsilon_{t-3}$$

Seterusnya daripada model-model yang diperolehi, perbandingan dibuat terhadap nilai ralat setiap model seperti yang terkandung dalam Lampiran L dengan pemilihan model peramalan diutamakan kepada model yang memiliki nilai MSE paling kecil. Hasil perbandingan tersebut, model ARMA peringkat (1,3) didapati paling sesuai untuk peramalan set data yang diberikan. Oleh itu, model ARMA(1,3) dipilih sebagai model untuk SEGAMAT. Graf ACF, PACF, histogram, dan kebarangkalian normal bagi model ditunjukkan pada Rajah 4.24



Rajah 4.22



Rajah 4.23

## **BAB 5**

### **REKABENTUK MODEL PERAMALAN RANGKAIAN NEURAL**

#### **5.1 Pengenalan**

Sebagaimana yang telah diketahui, sebanyak 16 buah stesen taburan hujan telah dipilih untuk membuat peramalan taburan hujan bagi negeri Johor. Bagi setiap daerah, sebanyak 2 buah stesen taburan hujan akan dipilih. Dengan itu, beberapa model rangkaian telah direkabentuk semasa proses merekabentuk model rangkaian mengikut setiap stesen. Bagi setiap stesen, model yang telah direkabentuk adalah sebanyak 63 model. Model yang direkabentuk ini bergantung kepada nilai kadar pembelajaran, momentum dan senibina rangkaian termasuk aras tersembunyi. Model-model tersebut pula akan disemak dan bagi model yang mempunyai nilai ralat validasi yang terkecil akan dipilih sebagai model yang terbaik bagi sesuatu stesen. Kemudian, nilai ramalan hujan bagi lima hari yang akan datang akan direkodkan. Ini bertujuan untuk meramalkan samada berlaku hujan atau tidak pada hari yang hendak diramalkan tersebut.

Bagi spesifikasi data input model rangkaian ini adalah melibatkan 7 nilai input. Iaitu dengan mengambil 7 hari sebagai data input. Data input merupakan data hujan harian dalam unit milimeter (mm). Manakala bagi spesifikasi output pula mengambil 5 nilai output data taburan hujan harian yang juga dalam unit milimeter (mm). Hasil output ramalan hujan untuk lima hari akan datang akan direkodkan. Bagi model yang mempunyai nilai ralat validasi yang terkecil akan dipilih sebagai model yang terbaik. Oleh itu, nilai bagi hasil output ramalan dan nilai ralat validasinya akan direkodkan.

## 5.2 Penjelmaan Data

Di dalam Bab 3 pada bahagian 3.6 telah diterangkan bahawa teknik penjelmaan data yang akan digunakan adalah penjelmaan linear. Penjelmaan Linear adalah bertujuan untuk mengelakkan masalah dalam pengiraan oleh rangkaian, membantu proses pembelajaran dalam rangkaian dan untuk memenuhi keperluan algoritma dalam membina rangkaian[9]. Selain itu, dengan melakukan penjelmaan terhadap data, masa pembelajaran dan penumpuan adalah lebih cepat. Nilai data yang telah dijelmakan akan berada di antara julat 0 dan 1. Jadual 5.1 di bawah menunjukkan data bagi Stesen Pintu Pasang Surut Kampung Sungai Rengit daerah Batu Pahat bagi bulan Januari tahun 2000 yang belum dijelmakan lagi. Manakala Jadual 5.2 pula adalah data bagi Stesen Pintu Pasang Surut Kampung Sungai Rengit daerah Batu Pahat bagi bulan Januari tahun 2000 yang telah dijelmakan. Jadual 5.1 dan 5.2 ini merupakan salah satu contoh data taburan hujan yang telah disusun. Formula bagi Penjelmaan Linear [9] adalah seperti berikut:

$$\text{Penjelmaan} : X_n = \frac{X_o - X_{\min}}{X_{\max} - X_{\min}}$$

di mana

$X_o$  = nilai asal bagi X (sebelum dijelmakan).

$X_n$  = nilai baru bagi X (nilai yang dijelmakan).

$X_{\min}$  = nilai X paling minima dalam sampel data.



**Jadual 5.2 :** Sebahagian data Stesen Pintu Pasang Surut Kampung Sungai Rengit Daerah Batu Pahat bagi bulan Januari tahun 2000 selepas penjelmaan.

ID	BLN	INPUT							OUTPUT				
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.20	0.07	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.20	0.07	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.20	0.07	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.20	0.07	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.20	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.20	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.20	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.20	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.00	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.00	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1631001	1	0.00	0.00	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

### 5.3 Pembahagian dan Penyusunan Data

Merujuk kepada Bab 3 dalam bahagian 3.6.7 iaitu langkah-langkah peramalan menggunakan kaedah rangkaian neural, apabila selesai sahaja proses penjelmaan data dibuat dengan menggunakan teknik penjelmaan linear, data taburan hujan tersebut akan dibahagikan kepada 3 bahagian. Data bagi tahun 2000 digunakan untuk proses pembelajaran, tahun 2001 pula digunakan untuk proses pengesahan atau validasi dan data taburan hujan bagi tahun 2002 untuk proses



peramalan. Data disusun menggunakan kaedah *Moving Average*. Bentuk sebahagian data yang disusun telah disertakan di dalam Lampiran D.

#### 5.4 Rekabentuk Model Rangkaian

Setelah proses penjelmaan data dan pembahagikan data kepada 3 bahagian iaitu pembelajaran, validasi dan peramalan dilakukan, pembinaan model rangkaian akan dilaksanakan pula. Model rangkaian yang akan dibina mempunyai 7 nod input, satu aras tersembunyi dan 5 nod output. Model rangkaian yang dibina adalah bertujuan untuk mendapatkan nilai ralat validasi yang terkecil dan seterusnya mendapatkan hasil ramalan hujan untuk 5 hari yang akan datang. Selain itu ia bertujuan untuk membuat analisa teknik peramalan rangkaian neural dalam membuat peramalan taburan hujan. Ia membawa maksud menentukan samada teknik yang digunakan ini sesuai atau tidak dalam membuat peramalan hujan.

Model-model rangkaian yang dibina mempunyai bilangan nod yang berlainan pada aras tersembunyi. Untuk kajian ini, bilangan nod tersembunyi telah dipilih dengan menggunakan formula pengiraan nod tersembunyi yang telah diterangkan dalam Bab 3. Formula bagi aras tersembunyi yang digunakan di dalam projek ini ialah  $n$ ,  $2n$  dan  $2n+1$  dengan nilai 7, 14 dan 15. Unit  $n$  mewakili bilangan input data. Fungsi penggiatan yang digunakan dalam projek ini ialah fungsi linear dan fungsi sigmoid. Penerangan mengenai fungsi-fungsi ini telah diterangkan di dalam Bab 3.

Pendekatan yang digunakan untuk membangunkan model rangkaian dalam projek ini ialah algoritma rambatan ke belakang. Penerangan mengenai rambatan ke belakang juga telah diterangkan dalam Bab 3. Algoritma pembelajaran yang digunakan dalam merekabentuk model rangkaian ialah *traingd*, *traingdm* dan *traingdx*. *Traingd* bermaksud menyelia proses pembelajaran yang dilakukan dengan mengemaskini nilai-nilai pemberat dan bias berdasarkan kecerunan rangkaian. *Traingdm* pula menyelia proses pembelajaran yang dilakukan dengan mengemaskini nilai-nilai pemberat dan bias rangkaian berdasarkan kecerunan rangkaian dengan

dipengaruhi oleh faktor nilai momentum. Algoritma *traingdx* pula membawa maksud menyelia proses pembelajaran yang dilakukan dengan mengemaskini nilai-nilai pemberat dan bias rangkaian berdasarkan kecerunan rangkaian dengan dipengaruhi oleh faktor nilai momentum dan juga faktor penyesuaian kadar pembelajaran.

#### **5.4.1 Arahan Merekabentuk Model Rangkaian dengan Menggunakan Perisian Matlab 6.1**

Perisian Matlab 6.1 digunakan dalam membangunkan model rangkaian taburan hujan. Beberapa arahan tertentu perlu dilaksanakan untuk merekabentuk model. Bagi penerangan secara terperinci, Stesen Ldg. Segamat di daerah Segamat akan dipilih. Stesen-stesen taburan hujan yang lain juga dilaksanakan dengan menggunakan kaedah yang sama untuk merekabentuk model. Hasil analisa setiap stesen akan diterangkan di dalam bab seterusnya. Penerangan hasil analisa bagi setiap stesen adalah menggunakan model rekabentuk yang terbaik, dengan nilai MSE validasi yang terkecil.

##### **5.4.1.1 Model Rangkaian bagi Stesen Ldg. Segamat Daerah Segamat.**

Model rangkaian yang direkabentuk ini mempunyai 3 aras iaitu 1 aras input, 1 aras tersembunyi dan 1 aras output. Nod aras tersembunyi ialah 7, dengan algoritma pembelajaran *traingdm*. Arahan kod aturcara ditulis pada antaramuka Editor *M-file* yang terdapat pada menu *File* di dalam Matlab. Sebelum memulakan sebarang arahan, data-data input dan output bagi data pembelajaran, validasi dan peramalan perlulah dipanggil dahulu. Data-data input dan output tersebut telah menjalani proses penjelmaan linear. Proses penjelmaan data telah dibuat dalam perisian *Excel*. Kod arahan untuk memanggil data tersebut adalah seperti berikut:

```
load ilbp74.txt;
```

```
load ivbp74.txt;
```

```
load olbp74.txt;
```

```
load ovbp74.txt;
```

**load ifbp74.txt;**

**load ofbp74.txt;**

di mana,

<b>ilbp74.txt</b>	adalah data input sebenar pembelajaran.
<b>olbp74.txt</b>	adalah data output sebenar pembelajaran.
<b>ivbp74.txt</b>	adalah data input sebenar pengesahan (validasi).
<b>ovbp74.txt</b>	adalah data output sebenar pengesahan (validasi).
<b>ifbp74.txt</b>	adalah data input sebenar peramalan.
<b>ofbp74.txt</b>	adalah data output sebenar peramalan.

Kemudian susunan matrik data perlu ditukarkan (*transpose*) dengan cara matrik baris ditukarkan ke matrik lajur begitu juga matrik lajur ditukarkan ke matrik baris. Ini kerana susunan matrik data yang akan digunakan adalah dalam keadaan *transpose*. Setiap data akan diisytiharkan dengan pembolehubah baru. Kesemua data yang telah ditukarkan susunan matriknya akan disimpan di dalam ruangan *workspace* pada perisian Matlab 6.1. Kod aturcaranya adalah:

```
transinL = transpose(ilbp74);  
transoutL = transpose(olbp74);  
transinV = transpose(ivbp74);  
transoutV = transpose(ovbp74);  
transinF = transpose(ifbp74);  
transoutF = transpose(ofbp74);
```

di mana,

<b>transinL</b>	adalah matrik <i>transpose</i> bagi data input sebenar pembelajaran.
<b>transoutL</b>	adalah matrik <i>transpose</i> bagi data output sebenar pembelajaran.
<b>transinV</b>	adalah matrik <i>transpose</i> bagi data input sebenar pengesahan.
<b>transoutV</b>	adalah matrik <i>transpose</i> bagi data output sebenar pengesahan.
<b>transinF</b>	adalah matrik <i>transpose</i> bagi data input sebenar

peramalan.

**transoutF** adalah matrik *transpose* bagi data output sebenar peramalan.

Sebelum data melakukan proses pembelajaran dan pengesahan, perkara yang perlu dilakukan dahulu ialah dengan mengisytiharkan satu objek rangkaian. Kod arahan adalah seperti di bawah:

```
net = newff(minmax(transinL),[H1 ,5],{ 'logsig','purelin'},'traingdm');
```

di mana, **newff** adalah fungsi yang dipanggil untuk membina rangkaian suap ke depan yang baru.

**minmax (transinL)** adalah fungsi yang akan mendapatkan nilai minimum dan maksima yang terdapat di dalam data input pembelajar, *transinL*.

**[H1,5]** adalah H1 menunjukkan nilai bagi nod tersembunyi. Nilai H1 telah diisytiharkan dahulu dengan nilai 7. Manakala nilai 5 pula membawa maksud bilangan nod output. Ia juga merupakan struktur rangkaian yang dibina.

**{'logsig','purelin'}** adalah menunjukkan jenis fungsi penggiatan yang digunakan dalam merekabentuk rangkaian. *Logsig* adalah fungsi penggiatan bagi aras tersembunyi. Manakala *purelin* pula ialah fungsi penggiatan yang digunakan untuk aras output.

**'traingdm'** adalah fungsi pembelajaran yang digunakan.

Terdapat satu arahan yang akan digunakan untuk mengosongkan semula semua pegangan nilai talian-talian berpemberat pada rangkaian sebelumnya. Ia

bermaksud nilai talian berpemberat yang menghubungkan nod-nod yang berkaitan mempunyai nilai bebas. Kod arahan tersebut adalah:

```
net = init(net);
```

Seterusnya rangkaian akan menggunakan beberapa arahan untuk mengisytiharkan parameter yang bertujuan sebagai panduan untuk merekabentuk rangkaian. Bagi fungsi pembelajaran *traingdm* dan *traingdx*, nilai momentum perlu diambil kira berbanding fungsi pembelajaran *traingd*. Nilai yang digunakan bagi parameter kadar pembelajaran (lr) ialah 0.1, 0.5 dan 0.9. Manakala nilai parameter bagi momentum (mc) pula ialah 0.1, 0.5 dan 0.9. Arahan tersebut adalah seperti di berikut:

<b>net.trainparam.lr = 0.1;</b>	adalah nilai parameter kadar pembelajaran.
<b>net.trainparam.mc = 0.9;</b>	adalah nilai parameter momentum.
<b>net.trainparam.epochs = 10000;</b>	adalah bilangan larian maksima yang ditetapkan.
<b>net.trainParam.goal = 0.01;</b>	adalah nilai sasaran pencapaian latihan.
<b>net.trainParam.show = 300;</b>	adalah nilai yang mempamerkan hasil larian latihan. Iaitu larian latihan 300 kali setiap paparan.


Apabila kesemua pembolehubah data, parameter-parameter yang berkaitan dan objek rangkaian telah diisytiharkan, maka rangkaian boleh dilatih. Arahan untuk melatih rangkaian adalah seperti berikut:

```
[net,tr] = train(net,transinL,transoutL);
```

di mana, **net** adalah rangkaian yang telah diisytiharkan.

- train** adalah fungsi yang digunakan untuk melatih rangkaian.
- transinL** adalah data input latihan.
- transoutL** adalah data output latihan.

Dengan terlaksananya arahan-arahan yang telah diterangkan di atas, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa, ukuran ralat akan terpapar. Rajah 5.1 menunjukkan paparan graf larian latihan dijanakan oleh Matlab 6.1 yang mencapai sasaran. Jadual 5.3 menunjukkan larian latihan model rangkaian. Merujuk kepada Jadual 5.3, sebanyak 801 larian untuk merekabentuk model rangkaian yang mencapai sasaran. MSE latihan pula ialah 0.009997.



**Rajah 5.1** Graf larian latihan yang mencapai sasaran

**Jadual 5.3** : Larian latihan model rangkaian

TRAIINGDM, Epoch 0/10000, MSE 2.76033/0.01, Gradient 2.88003/1e-010
TRAIINGDM, Epoch 300/10000, MSE 0.0146277/0.01, Gradient 0.011941/1e-010
TRAIINGDM, Epoch 600/10000, MSE 0.0113798/0.01, Gradient 0.00895565/1e-010
TRAIINGDM, Epoch 801/10000, MSE 0.00999676/0.01, Gradient 0.00761599/1e-010
TRAIINGDM, Performance goal met

Seterusnya, data latihan akan disimulasikan. Dan kemudian nilai MSE latihan akan diperolehi. Walau bagaimana pun, nilai MSE latihan tidak diambil sebagai pengukur model terbaik. Kod arahan adalah seperti berikut:

```
Latih = sim(net,transinL);  
mseLatih = mse(transoutL-Latih);
```

Langkah yang seterusnya selepas melakukan proses pembelajaran dan latihan, ialah proses pengesahan. Sebagaimana yang telah diketahui, pada awal kod arahan telah mengisytiharkan pembolehubah bagi data input validasi (*transinV*) dan data output validasi (*transoutV*). Jadual 5.4 menunjukkan hasil MSE validasi terkecil. Lampiran AB1 menunjukkan larian latihan model rangkaian dan hasil bagi MSE validasi terkecil bagi stesen ini. Arahan di bawah melaksanakan proses untuk melakukan validasi data:

```
Validation = sim(net,transinV);  
mseValidasi = mse(transoutV-Validation);
```

di mana,	<b>Validation</b>	adalah pembolehubah baru data output validasi model rangkaian.
	<b>sim</b>	adalah fungsi untuk proses simulasi.
	<b>net</b>	adalah rangkaian yang telah diisytiharkan.
	<b>transinV</b>	adalah data input validasi.
	<b>mseValidasi</b>	adalah pembolehubah yang memegang nilai MSE validasi.
	<b>mse</b>	adalah fungsi untuk mendapatkan nilai MSE.
	<b>transoutV</b>	adalah pembolehubah data output validasi.

**Jadual 5.4 : Hasil MSE validasi**

<p>Nilai Mean Square Error (MSE) Validasi ialah 0.020594</p>
--

Nilai MSE validasi yang terhasil bagi setiap model akan direkodkan dan disimpan. Ia bertujuan untuk mengenalpasti model yang mana akan menghasilkan nilai MSE validasi yang terkecil. Bagi model yang mempunyai nilai MSE terkecil akan dipilih sebagai model yang terbaik. Rajah 5.2 menunjukkan graf validasi bagi data taburan hujan.


Bagi model rangkaian terbaik berdasarkan dengan nilai MSE validasi terkecil, seterusnya proses peramalan akan dilaksanakan. Rajah 5.3 adalah graf bandingan bagi data sebenar dengan data ramalan hujan. Kod arahan adalah:

**Forecast = sim(net,transinF);**

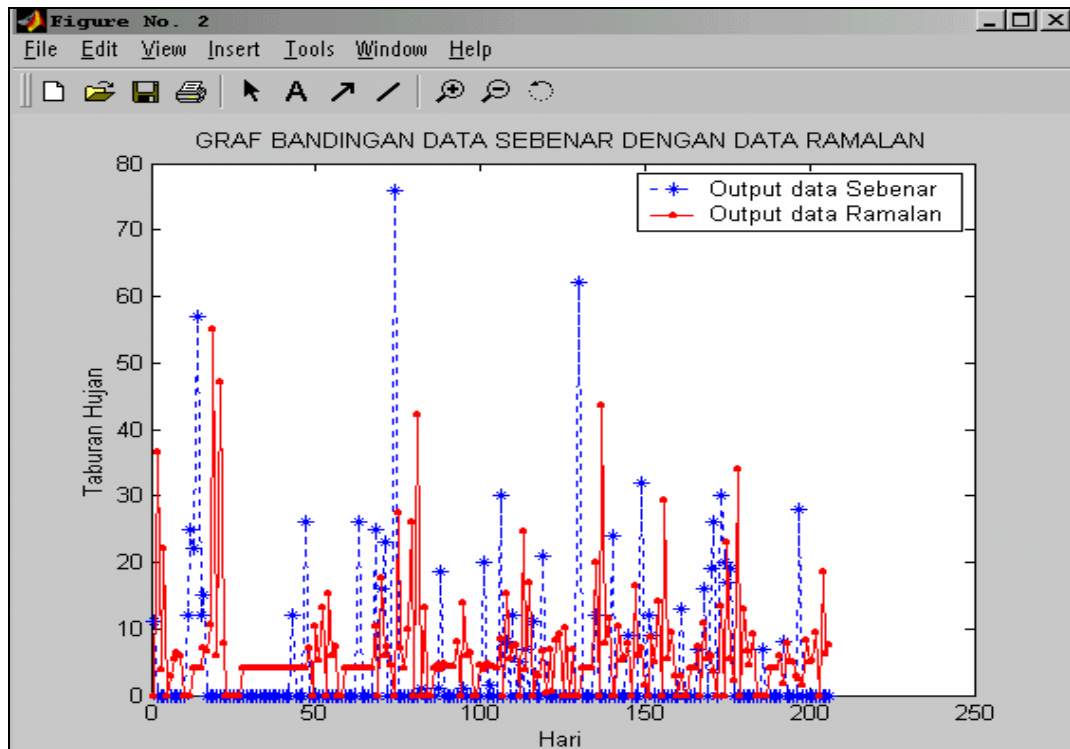
di mana,	<b>Forecast</b>	adalah pembolehubah baru data output hasil peramalan model rangkaian.
	<b>sim</b>	adalah fungsi untuk proses simulasi.
	<b>net</b>	adalah rangkaian yang telah diisytiharkan.



transinF adalah data input peramalan



Rajah 5.2 Graf validasi taburan hujan.



### Rajah 5.3 Graf bandingan data sebenar dengan data ramalan hujan

Langkah seterusnya selepas melaksanakan proses peramalan ialah melakukan proses penjelmaan semula data. Ini bertujuan untuk mendapatkan nilai data taburan hujan dalam unit milimeter. Kod sintak untuk melakukan penjelmaan semula data ialah:

$$\begin{aligned} \mathbf{A1} &= (\mathbf{transoutL}*(\mathbf{300-0})+\mathbf{0}); & \mathbf{A2} &= (\mathbf{Latih}*(\mathbf{300-0})+\mathbf{0}); \\ \mathbf{B1} &= (\mathbf{transoutV}*(\mathbf{300-0})+\mathbf{0}); & \mathbf{B2} &= (\mathbf{Validation}*(\mathbf{300-0})+\mathbf{0}); \\ \mathbf{C1} &= (\mathbf{transoutF}*(\mathbf{300-0})+\mathbf{0}); & \mathbf{C2} &= (\mathbf{Forecast}*(\mathbf{300-0})+\mathbf{0}); \end{aligned}$$

- di mana
- A1** adalah pembolehubah baru bagi data output latihan untuk penjelmaan semula data.
  - A2** adalah pembolehubah baru bagi data input latihan yang telah disimulasikan untuk penjelmaan semula data.
  - B1** adalah pembolehubah baru bagi data output validasi untuk penjelmaan semula data.
  - B2** adalah pembolehubah baru bagi data input validasi yang telah disimulasikan untuk penjelmaan semula data.
  - C1** adalah pembolehubah baru bagi data output ramalan untuk penjelmaan semula data.
  - C2** adalah pembolehubah baru bagi data input ramalan yang telah disimulasikan untuk penjelmaan semula data.
  - 300** adalah nilai maksima bagi sampel data hujan.
  - 0** adalah nilai minima bagi sampel data hujan.

Bagi kesemua nilai data-data yang belum dijelmakan, sudah dijelmakan dan data hasil output bagi model rangkaian yang terbaik akan disimpan di ruangan *workspace*. Ia bertujuan untuk memudahkan membuat semakkan atau rujukan pada bahagian analisa. Selain itu ia bertujuan untuk menghasilkan model peramalan.

Graf hasil ramalan juga akan disimpan. Penerangan analisa mengenai hasil ramalan ini akan diterangkan di dalam bab seterusnya.

## **BAB 6**

### **ANALISA HASIL**

#### **6.1 Pengenalan**

Di dalam bab ini, model terbaik yang diperolehi hasil daripada rekabentuk model yang dihasilkan dalam Bab 4 dan 5 akan digunakan untuk mendapatkan hasil output peramalan. Analisa mengenai teknik yang digunakan berdasarkan kepada model yang terbaik juga akan di lakukan di dalam bab ini. Pada bahagian ini analisa hasil akan di pecahkan kepada 2 bahagian iaitu analisa hasil melalui kaedah Box Jenkins yang akan diterangkan pada bahagian 6.2 dan analisa hasil melalui kaedah Rangkaian Neural yang akan diterangkan pada bahagian 6.3.


#### **6.2 Analisa Hasil Peramalan Melalui Kaedah Box-Jenkins**

Setelah pemilihan model peramalan yang paling sesuai dibuat, peramalan akan dibuat berdasarkan model yang terpilih. Dengan model yang terpilih tersebut, nilai peramalan ditentukan dan dibandingkan dengan data asal. Melalui perbandingan tersebut, beberapa rumusan dibuat bagi mengetahui sama ada model peramalan

adalah sesuai untuk peramalan data hujan dan sama ada kaedah peramalan Box-Jenkins adalah sesuai untuk peramalan taburan hujan seterusnya peramalan banjir.

### 6.2.1 Daerah Batu Pahat


Rajah 6.1 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Nilai ralat juga tidaklah terlalu besar dengan ralat maksimum yang diperolehi adalah 3.942011. Namun demikian, data ramalan kurang peka terhadap perubahan mengejut pada data sebenar. Secara keseluruhannya, taburan hujan bagi BATU PAHAT tidak memperlihatkan perbezaan jumlah hujan yang jelas dari awal tahun ke akhir tahun di samping kadar hujan di bawah 20 mm sehari.



**Rajah 6.1:** Graf perbandingan data asal Daerah Batu Pahat dengan hasil ramalan

### 6.2.2 Daerah Johor Bahru

Rajah 6.2 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian, terdapat data ramalan yang tersasar di bawah kosong. Ini adalah tidak munasabah sama sekali kerana data hujan tidak boleh berada di bawah paras sifar. Oleh itu model peramalan ini tidak dapat meramalkan data hujan dengan baik. Walau bagaimanapun, dari pada pemerhatian terhadap kedua-dua graf data asal dan data ramalan mendapati taburan hujan yang semakin meningkat terutamanya pada akhir tahun dengan jumlah hujan melebihi 25 mm sehari.




**Rajah 6.2:** Graf perbandingan data asal Daerah Johor Bahru dengan hasil ramalan

### 6.2.3 Daerah Kluang

Rajah 6.3 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat juga jumlah ralat yang

terlalu tinggi terutama pada data ke-6 hingga ke-8 dengan ralat melebihi 3 mm. Secara umumnya, taburan hujan di daerah KLUANG A adalah tinggi pada awal tahun dengan jumlah hujan mencapai 15mm sehari dan mengalami kekurangan hujan pada pertengahan hujan dengan jumlah hujan hampir kepada 0 mm sehari.




**Rajah 6.3:** Graf perbandingan data asal Daerah Kluang dengan hasil ramalan

#### 6.2.4 Daerah Kota Tinggi

Rajah 6.4 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat nilai ramalan yang kurang daripada 0. Ini adalah tidak munasabah sama sekali kerana data hujan tidak boleh kurang daripada 0 mm. Selain model data juga kurang peka terutamanya pada data ke-70 hingga 74 di mana data sebenar mengalami penurunan dan kenaikan yang mendadak tetapi tidak dapat dikesan oleh model peramalan terpilih. Secara umumnya,

taburan hujan di daerah KOTA TINGGI adalah tinggi pada awal tahun dengan jumlah hujan melebihi 15mm sehari dan mengalami kekurangan hujan pada pertengahan hujan dengan jumlah hujan hampir kepada 0 mm sehari dan menaik semula pada akhir tahun secara mendadak.




**Rajah 6.4:** Graf perbandingan data asal Daerah Kota Tinggi dengan hasil ramalan

### 6.2.5 Daerah Mersing

Rajah 6.5 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat nilai hasil peramalan yang kurang daripada 0. Ini adalah tidak munasabah sama sekali kerana data hujan tidak boleh bernilai kurang daripada 0 mm sehari. Model data pula dilihat boleh mengesan perubahan mendadak data sebenar dengan agak baik. Secara umumnya, taburan hujan di daerah MERSING adalah hampir sekata sepanjang tahun melainkan

terdapat tonjolan mendadak pada awal dan akhir tahun dengan kadar hujan melebihi 20 mm dan 30 mm sehari pada kedua-dua tonjolan tersebut.




**Rajah 6.5:** Graf perbandingan data asal Daerah Mersing dengan hasil ramalan

### 6.2.6 Daerah Muar

Rajah 6.6 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat juga jumlah ralat yang terlalu tinggi terutama pada data ke-6 dan data ke-42 dengan ralat melebihi 3 mm. Secara umumnya, taburan hujan di daerah MUAR A adalah hampir sekata sepanjang tahundengan tidak menampakkan perubahan jelas dari awal hingga ke akhir tahun dengan purata sekitar 9mm sehari.






**Rajah 6.6:** Graf perbandingan data asal Daerah Muar dengan hasil ramalan

### 6.2.7 Daerah Pontian

Rajah 6.7 adalah dirujuk. Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat nilai hasil peramalan yang kurang daripada 0. Ini adalah tidak munasabah sama sekali kerana data hujan tidak boleh bernilai kurang daripada 0 mm sehari. Secara umumnya, taburan hujan di daerah MUAR B adalah sukar ditentukan kerana taburan hujan yang sekata

sepanjang tahun melainkan kenaikan mendadak pada hujung tahun dengan julat hujan kira-kira 14 mm.




**Rajah 6.7:** Graf perbandingan data asal Daerah Pontian dengan hasil ramalan

### 6.2.8 Daerah Segamat

Rajah 6.8 adalah dirujuk Hasil daripada kajian yang telah dibuat, hasil peramalan dengan kaedah Box-Jenkins masih menunjukkan prestasi yang memuaskan. Ini adalah kerana corak yang ditunjukkan masih mengikut corak taburan hujan di satu-satu daerah tersebut. Namun demikian terdapat nilai hasil peramalan yang kurang daripada 0. Ini adalah tidak munasabah sama sekali kerana data hujan tidak boleh bernilai kurang daripada 0 mm sehari. Selain itu terdapat julat ralat yang

agak besar pada data ke-9, 37, dan 48. Secara umumnya, taburan hujan di daerah SEGAMAT adalah agak sekata melain tonjolan pada awal tahun.



**Rajah 6.8:** Graf perbandingan data asal Daerah Segamat dengan hasil ramalan

### 6.3 Analisa Hasil Peramalan Melalui Kaedah Rangkaian Neural

Sebagaimana yang telah diketahui, sebanyak 63 model rangkaian telah dibangunkan bagi setiap stesen taburan hujan. Model-model yang dibangunkan ini menggabungkan parameter-parameter tertentu yang menjalani proses pembelajaran atau latihan dan seterusnya disahkan dengan menggunakan perisian Matlab 6.1. Parameter tersebut ialah kadar pembelajaran dan momentum. Nilai-nilai parameter

bagi kadar pembelajaran dan momentum telah diterangkan di dalam Bab 5. Bagi model-model yang telah dibangunkan, hanya model yang terbaik sahaja bagi setiap stesen akan digunakan untuk mendapatkan hasil output peramalan taburan hujan untuk lima hari akan datang dan akan dianalisa. Model yang mempunyai ralat validasi terkecil adalah merupakan model yang terbaik.

Model-model yang telah direkabentuk di dalam Bab 5, merupakan 16 stesen taburan hujan di negeri Johor. Senarai stesen taburan hujan yang dipilih boleh merujuk Lampiran A. Bagi setiap stesen, fungsi penggiatan, aras tersembunyi dan aras output telah diselaraskan. *Logsig* digunakan untuk fungsi penggiatan pada aras tersembunyi, dan fungsi penggiatan bagi aras output pula ialah *purelin*. Nod tersembunyi juga diselaraskan bagi setiap larian. Iaitu 7, 14 dan 15. Bagi setiap model yang dibangunkan, nilai kadar pembelajaran adalah tetap iaitu 0.1, 0.5 dan 0.9. Begitu juga dengan nilai momentum dengan nilai 0.1, 0.5 dan 0.9. Penggunaan nilai kadar pembelajaran dan momentum adalah mengikut susunan dari nilai kecil ke nilai besar. Sebagai contoh, penggunaan nilai 0.1 kemudian diikuti dengan 0.5 dan seterusnya 0.9. Tiga fungsi pembelajaran yang digunakan untuk membangunkan model rangkaian ini ialah fungsi *traingd*, *traingdm* dan *traingdx*. Penerangan mengenai fungsi-fungsi pembelajaran ini telah diterangkan di dalam Bab 5.

Model yang terbaik akan dianalisa untuk mengenalpasti sama ada teknik peramalan rangkaian neural ini dapat menghasilkan model peramalan taburan hujan yang baik atau sebaliknya. Penerangan mengenai analisa setiap model rangkaian yang terbaik bagi setiap stesen akan dihuraikan di dalam bab ini pada bahagian seterusnya.

### **6.3.1 Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat**

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa proses larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.1(i) di bawah menunjukkan

model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.1(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.1(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.1(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	828	0.009997	0.011668
<b>0.5</b>	64	0.009941	0.010682
<b>0.9</b>	109	0.009893	0.010158
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1114	0.009997	0.011481
<b>0.5</b>	229	0.009975	0.009511
<b>0.9</b>	161	0.009962	0.014529
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1115	0.009996	0.013400
<b>0.5</b>	256	0.009979	0.012575
<b>0.9</b>	119	0.009922	0.013175

**Jadual 6.1(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	505	0.009994	0.012848
	<b>0.5</b>	624	0.009994	0.014491
	<b>0.9</b>	638	0.009999	0.012129
<b>0.5</b>	<b>0.1</b>	139	0.009999	0.010789
	<b>0.5</b>	134	0.009999	0.010386
	<b>0.9</b>	164	0.009937	0.013486
<b>0.9</b>	<b>0.1</b>	87	0.009930	0.012338
	<b>0.5</b>	76	0.009929	0.012732
	<b>0.9</b>	57	0.009706	0.010104
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>

<b>0.1</b>	<b>0.1</b>	903	0.009996	0.010850
	<b>0.5</b>	1154	0.009996	0.015306
	<b>0.9</b>	913	0.009994	0.013307
<b>0.5</b>	<b>0.1</b>	246	0.009981	0.012112
	<b>0.5</b>	241	0.009980	0.011071
	<b>0.9</b>	214	0.009987	0.010981
<b>0.9</b>	<b>0.1</b>	159	0.009993	0.012204
	<b>0.5</b>	148	0.009969	0.013258
	<b>0.9</b>	<b>92</b>	<b>0.009663</b>	<b>0.008263</b>
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1688	0.009998	0.014748
	<b>0.5</b>	1144	0.009996	0.012166
	<b>0.9</b>	1791	0.009998	0.011729
<b>0.5</b>	<b>0.1</b>	199	0.009959	0.013248
	<b>0.5</b>	201	0.009986	0.011770
	<b>0.9</b>	118	0.009919	0.010889
<b>0.9</b>	<b>0.1</b>	186	0.009981	0.011791
	<b>0.5</b>	146	0.009961	0.011523
	<b>0.9</b>	108	0.009911	0.010138

**Jadual 6.1(iii)** : Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Pintu Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat

<b>Fungsi Pembelajaran : <i>TRAINGDX</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	73	0.009715	0.011783
	<b>0.5</b>	74	0.009973	0.010570
	<b>0.9</b>	87	0.009800	0.012495
<b>0.5</b>	<b>0.1</b>	44	0.009806	0.012640
	<b>0.5</b>	52	0.009737	0.010990
	<b>0.9</b>	64	0.009685	0.011048
<b>0.9</b>	<b>0.1</b>	56	0.009754	0.012695
	<b>0.5</b>	42	0.009938	0.014426
	<b>0.9</b>	65	0.009983	0.012507
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	224	0.009979	0.011316
	<b>0.5</b>	79	0.009985	0.013107
	<b>0.9</b>	96	0.009689	0.012265
<b>0.5</b>	<b>0.1</b>	217	0.009859	0.012460
	<b>0.5</b>	77	0.009887	0.011494
	<b>0.9</b>	64	0.009825	0.012256
<b>0.9</b>	<b>0.1</b>	193	0.009934	0.014322
	<b>0.5</b>	85	0.009948	0.011956

	<b>0.9</b>	86	0.009951	0.012276
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	136	0.009997	0.012757
	<b>0.5</b>	102	0.009988	0.010885
	<b>0.9</b>	103	0.009759	0.012484
<b>0.5</b>	<b>0.1</b>	159	0.009950	0.014285
	<b>0.5</b>	89	0.009949	0.011353
	<b>0.9</b>	78	0.009819	0.012497
<b>0.9</b>	<b>0.1</b>	145	0.009888	0.010635
	<b>0.5</b>	119	0.009948	0.010619
	<b>0.9</b>	79	0.009670	0.013207

Berpandukan kepada Jadual 6.1(i), Jadual 6.1(ii) dan Jadual 6.1(iii), didapati ralat validasi terkecil bagi Stesen Pintu Pasang Surut Kg. Sg. Rengit daerah Batu Pahat ialah 0.008263. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.1(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran M1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.1(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.9 dan 0.9. Manakala nilai 14 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.1 (iv) :** Model rangkaian yang terbaik bagi Stesen Pasang Surut Kg. Sg. Rengit Daerah Batu Pahat

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi : 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.9	0.9	92	0.008263	6.0 6.5 6.1 7.1 5.9

Merujuk kepada Lampiran M2, didapati bahawa sebanyak 92 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran M3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data

validasi. Lampiran M4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada kelima-lima hari dengan merujuk nilai hasil ramalan hujan pada Jadual 6.1(iv) di atas.

### 6.3.2 Stesen Ldg. Union Yong Peng Daerah Batu Pahat

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa proses larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.2(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.2(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.2(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.015, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.2(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Union Yong Peng Daerah Batu Pahat

<b>Fungsi Pembelajaran : TRAINGD</b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1702	0.014999	0.021544
<b>0.5</b>	162	0.014986	0.022906
<b>0.9</b>	152	0.014989	0.023097
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1674	0.015000	0.024731
<b>0.5</b>	311	0.014999	0.028035
<b>0.9</b>	257	0.014995	0.026969
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2011	0.014998	0.024679



<b>0.5</b>	443	0.014999	0.028974
<b>0.9</b>	258	0.014993	0.025348

**Jadual 6.2(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Union Yong Peng Daerah Batu Pahat

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	906	0.014999	0.023193
	<b>0.5</b>	1325	0.014999	0.023045
	<b>0.9</b>	1225	0.014999	0.024673
<b>0.5</b>	<b>0.1</b>	306	0.014994	0.021917
	<b>0.5</b>	250	0.014998	0.024052
	<b>0.9</b>	287	0.014986	0.023699
<b>0.9</b>	<b>0.1</b>	152	0.014994	0.023486
	<b>0.5</b>	<b>168</b>	<b>0.014999</b>	<b>0.021370</b>
	<b>0.9</b>	109	0.014996	0.024689
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1881	0.014999	0.023293
	<b>0.5</b>	2083	0.014999	0.022338
	<b>0.9</b>	2003	0.015000	0.023008
<b>0.5</b>	<b>0.1</b>	468	0.014995	0.024466
	<b>0.5</b>	475	0.015000	0.026356
	<b>0.9</b>	445	0.014995	0.025792
<b>0.9</b>	<b>0.1</b>	267	0.014995	0.024670
	<b>0.5</b>	194	0.014990	0.028834
	<b>0.9</b>	92	0.014827	0.026286
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	2272	0.014999	0.024867
	<b>0.5</b>	2414	0.015000	0.024392
	<b>0.9</b>	3164	0.015000	0.027348
<b>0.5</b>	<b>0.1</b>	370	0.014989	0.022972
	<b>0.5</b>	396	0.014996	0.023974
	<b>0.9</b>	253	0.014998	0.024043
<b>0.9</b>	<b>0.1</b>	219	0.014988	0.026842
	<b>0.5</b>	261	0.014996	0.027645
	<b>0.9</b>	225	0.014996	0.025265

**Jadual 6.2(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Ldg. Union Yong Peng Daerah Batu Pahat

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	106	0.014639	0.021509
	<b>0.5</b>	86	0.014930	0.023921
	<b>0.9</b>	97	0.014974	0.023646
<b>0.5</b>	<b>0.1</b>	101	0.014949	0.021392
	<b>0.5</b>	65	0.014985	0.022030
	<b>0.9</b>	71	0.014917	0.024353
<b>0.9</b>	<b>0.1</b>	104	0.014965	0.022703
	<b>0.5</b>	59	0.014908	0.022582
	<b>0.9</b>	78	0.014833	0.022963
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	351	0.014994	0.024821
	<b>0.5</b>	106	0.014944	0.024068
	<b>0.9</b>	104	0.014876	0.025890
<b>0.5</b>	<b>0.1</b>	416	0.014985	0.024492
	<b>0.5</b>	127	0.014965	0.025201
	<b>0.9</b>	79	0.014966	0.024161
<b>0.9</b>	<b>0.1</b>	300	0.014989	0.026240
	<b>0.5</b>	164	0.014999	0.023482
	<b>0.9</b>	177	0.014991	0.028198
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	274	0.014984	0.024151
	<b>0.5</b>	173	0.014994	0.023085
	<b>0.9</b>	117	0.014859	0.024606
<b>0.5</b>	<b>0.1</b>	284	0.014991	0.024192
	<b>0.5</b>	164	0.014987	0.024356
	<b>0.9</b>	90	0.014986	0.023600
<b>0.9</b>	<b>0.1</b>	215	0.014996	0.024170
	<b>0.5</b>	191	0.014990	0.023713
	<b>0.9</b>	90	0.014847	0.023865

Berpandukan kepada Jadual 6.2(i), Jadual 6.2(ii) dan Jadual 6.2(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Union Yong Peng Daerah Batu Pahat ialah 0.021370. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.2(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran N1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.2(iv) di bawah menunjukkan model rangkaian

terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.9 dan 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.2 (iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Union Yong Peng Daerah Batu Pahat

<b>Fungsi Pembelajaran : <i>TRAINGDM</i></b>				
<b>Nod Tersembunyi : 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.9	0.5	168	0.021370	4.7 0.0 2.3 4.5 5.4

Merujuk kepada Lampiran N2, didapati bahawa sebanyak 168 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran N3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran N4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, ketiga, keempat dan kelima, manakala hari kedua tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.2(iv) di atas.

### **6.3.3 Stesen Ldg. Senai Daerah Johor Bahru**

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa proses larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan ter papar. Jadual 6.3(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.3(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.3(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx*

sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.3(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Senai Daerah Johor Bahru

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1423	0.009998	0.016597
<b>0.5</b>	192	0.010000	0.020330
<b>0.9</b>	167	0.009983	0.017811
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1779	0.009998	0.020586
<b>0.5</b>	440	0.009999	0.020775
<b>0.9</b>	251	0.009986	0.022113
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1562	0.009997	0.020766
<b>0.5</b>	573	0.009994	0.021190
<b>0.9</b>	158	0.009992	0.017540

**Jadual 6.3(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Senai Daerah Johor Bahru

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1004	0.009998	0.018170
	<b>0.5</b>	1065	0.009998	0.017267
	<b>0.9</b>	872	0.009996	0.015410
<b>0.5</b>	<b>0.1</b>	287	0.009996	0.017997
	<b>0.5</b>	224	0.009994	0.019664
	<b>0.9</b>	186	0.009975	0.018981
<b>0.9</b>	<b>0.1</b>	132	0.009963	0.018681
	<b>0.5</b>	120	0.009966	0.020383
	<b>0.9</b>	90	0.009928	0.020566
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1651	0.009998	0.021213

	<b>0.5</b>	2066	0.009999	0.018592
	<b>0.9</b>	1804	0.009999	0.023406
<b>0.5</b>	<b>0.1</b>	410	0.009989	0.018338
	<b>0.5</b>	416	0.009991	0.018574
	<b>0.9</b>	439	0.009993	0.017463
<b>0.9</b>	<b>0.1</b>	184	0.009985	0.017914
	<b>0.5</b>	260	0.009983	0.019251
	<b>0.9</b>	120	0.009993	0.034541
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	2310	0.009999	0.021541
	<b>0.5</b>	2652	0.010000	0.018032
	<b>0.9</b>	2626	0.009998	0.020482
<b>0.5</b>	<b>0.1</b>	315	0.009997	0.020867
	<b>0.5</b>	392	0.009996	0.016810
	<b>0.9</b>	489	0.009994	0.019437
<b>0.9</b>	<b>0.1</b>	376	0.009999	0.018940
	<b>0.5</b>	319	0.009995	0.019346
	<b>0.9</b>	187	0.009989	0.020451

**Jadual 6.3(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ldg. Senai Daerah Johor Bahru

<b>Fungsi Pembelajaran : TRAINIDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	79	0.009971	0.021032
	<b>0.5</b>	84	0.009975	0.015469
	<b>0.9</b>	96	0.009926	0.017593
<b>0.5</b>	<b>0.1</b>	<b>65</b>	<b>0.009999</b>	<b>0.014798</b>
	<b>0.5</b>	61	0.009797	0.017289
	<b>0.9</b>	68	0.009817	0.018453
<b>0.9</b>	<b>0.1</b>	93	0.009983	0.018496
	<b>0.5</b>	52	0.009843	0.017451
	<b>0.9</b>	66	0.009989	0.020172
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	309	0.009936	0.016072
	<b>0.5</b>	117	0.009948	0.018682
	<b>0.9</b>	108	0.009846	0.017641
<b>0.5</b>	<b>0.1</b>	244	0.009989	0.018759
	<b>0.5</b>	140	0.009867	0.020739
	<b>0.9</b>	72	0.009889	0.016350
<b>0.9</b>	<b>0.1</b>	279	0.009981	0.019737
	<b>0.5</b>	118	0.009974	0.019387
	<b>0.9</b>	93	0.009979	0.016618
<b>Nod Tersembunyi = 15</b>				

Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	231	0.009889	0.021410
	0.5	175	0.009984	0.018353
	0.9	111	0.009793	0.018928
0.5	0.1	327	0.009986	0.021536
	0.5	132	0.009965	0.019996
	0.9	86	0.009833	0.018919
0.9	0.1	386	0.009999	0.025545
	0.5	185	0.009959	0.019999
	0.9	93	0.009831	0.019242

Berpandukan kepada Jadual 6.3(i), Jadual 6.3(ii) dan Jadual 6.3(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Senai Daerah Johor Bahru ialah 0.014798. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.3(iii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran O1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.3(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.5 dan 0.1. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdx* sebagai fungsi pembelajaran.

**Jadual 6.3(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Senai  
Daerah Johor Bahru

Fungsi Pembelajaran : <i>TRAININGDX</i>				
Nod Tersembunyi : 7				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
0.5	0.1	65	0.014798	4.9 0.0 3.9 19.1 0.0

Merujuk kepada Lampiran O2, didapati bahawa sebanyak 65 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran O3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran O4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan hari pertama, ketiga dan keempat, manakala hari kedua dan kelima tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.3(iv) di atas.

#### 6.3.4 Stesen Ldg. Sg. Tiram Daerah Johor Bahru

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.4(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.4(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.4(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.4(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Sg. Tiram Daerah Johor Bahru

<b>Fungsi Pembelajaran :TRAIINGD</b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	670	0.009990	0.035124
<b>0.5</b>	67	0.009982	0.042734
<b>0.9</b>	119	0.009876	0.023927
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	927	0.009993	0.032342
<b>0.5</b>	256	0.009988	0.051043
<b>0.9</b>	124	0.009973	0.047311
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	948	0.009992	0.044817
<b>0.5</b>	287	0.009988	0.048226

<b>0.9</b>	99	0.009924	0.030484
------------	----	----------	----------

**Jadual 6.4(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Sg. Tiram Daerah Johor Bahru

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	422	0.009995	0.032389
	<b>0.5</b>	375	0.009994	0.060063
	<b>0.9</b>	<b>754</b>	<b>0.009998</b>	<b>0.019315</b>
<b>0.5</b>	<b>0.1</b>	141	0.009995	0.023862
	<b>0.5</b>	109	0.009935	0.036649
	<b>0.9</b>	118	0.009928	0.027390
<b>0.9</b>	<b>0.1</b>	77	0.009951	0.028218
	<b>0.5</b>	73	0.009949	0.027515
	<b>0.9</b>	56	0.009902	0.043595
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	815	0.009996	0.048095
	<b>0.5</b>	987	0.010000	0.046155
	<b>0.9</b>	742	0.009988	0.043628
<b>0.5</b>	<b>0.1</b>	186	0.009998	0.065242
	<b>0.5</b>	198	0.009970	0.036620
	<b>0.9</b>	208	0.009969	0.048576
<b>0.9</b>	<b>0.1</b>	122	0.009981	0.054787
	<b>0.5</b>	116	0.009950	0.044159
	<b>0.9</b>	98	0.009933	0.050291
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1287	0.010000	0.053235
	<b>0.5</b>	1302	0.009999	0.043275
	<b>0.9</b>	1546	0.009994	0.037911
<b>0.5</b>	<b>0.1</b>	149	0.009964	0.035817
	<b>0.5</b>	219	0.009979	0.026370
	<b>0.9</b>	133	0.009954	0.049513
<b>0.9</b>	<b>0.1</b>	140	0.009972	0.044181
	<b>0.5</b>	140	0.009996	0.041976
	<b>0.9</b>	90	0.009943	0.065390



**Jadual 6.4(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ldg. Sg. Tiram Daerah Johor Bahru

<b>Fungsi Pembelajaran :<i>TRAINIDX</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	69	0.009771	0.033347
	<b>0.5</b>	69	0.009906	0.032840
	<b>0.9</b>	83	0.009715	0.028441
<b>0.5</b>	<b>0.1</b>	41	0.009861	0.031842
	<b>0.5</b>	47	0.009655	0.031107
	<b>0.9</b>	57	0.009967	0.038814
<b>0.9</b>	<b>0.1</b>	47	0.009952	0.024689
	<b>0.5</b>	43	0.009778	0.035064
	<b>0.9</b>	58	0.009975	0.025291
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	163	0.009932	0.034190
	<b>0.5</b>	78	0.009743	0.029498
	<b>0.9</b>	90	0.009859	0.031968
<b>0.5</b>	<b>0.1</b>	192	0.009973	0.038980
	<b>0.5</b>	73	0.009932	0.048330
	<b>0.9</b>	61	0.009559	0.030613
<b>0.9</b>	<b>0.1</b>	162	0.009978	0.037337
	<b>0.5</b>	68	0.009934	0.033510
	<b>0.9</b>	85	0.009663	0.039269
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	109	0.009971	0.052935
	<b>0.5</b>	83	0.009860	0.032016
	<b>0.9</b>	98	0.009634	0.041633
<b>0.5</b>	<b>0.1</b>	161	0.009992	0.041911
	<b>0.5</b>	74	0.009951	0.062115
	<b>0.9</b>	74	0.009844	0.055079
<b>0.9</b>	<b>0.1</b>	132	0.009966	0.075050
	<b>0.5</b>	87	0.009935	0.060938
	<b>0.9</b>	75	0.009814	0.039854

Berpandukan kepada Jadual 6.4(i), Jadual 6.4(ii) dan Jadual 6.4(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Sg. Tiram Daerah Johor Bahru ialah 0.019315. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.4(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran P1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.4(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.9. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.4(iv) : Model rangkaian yang terbaik bagi Stesen Ldg. Sg. Tiram  
Daerah Johor Bahru**

<b>Fungsi Pembelajaran : <i>TRAINGDM</i></b>				
<b>Nod Tersembunyi :7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.1	0.9	754	0.019315	56.8 14.4 13.8 0.0 15.0

Merujuk kepada Lampiran P2, didapati bahawa sebanyak 754 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran P3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran P4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, ketiga dan kelima, manakala hari keempat tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.4(iv) di atas.

### **6.3.5 Stesen Ldg. Simpang Renggam Daerah Kluang**

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.5(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.5(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.5(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.015, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.5(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Simpang Renggam Daerah Kluang

<b>Fungsi Pembelajaran :TRAIINGD</b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	818	0.014999	0.020225
<b>0.5</b>	61	0.014975	0.020560
<b>0.9</b>	118	0.014966	0.020581
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1013	0.014996	0.022401
<b>0.5</b>	187	0.014988	0.025759
<b>0.9</b>	119	0.014989	0.025999
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1068	0.014994	0.023251
<b>0.5</b>	286	0.014996	0.022855
<b>0.9</b>	142	0.014992	0.021868

**Jadual 6.5(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Simpang Renggam Daerah Kluang

<b>Fungsi Pembelajaran :TRAIINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	466	0.014989	0.020334
	<b>0.5</b>	354	0.014996	0.023201

	<b>0.9</b>	727	0.014996	0.018495
<b>0.5</b>	<b>0.1</b>	<b>150</b>	<b>0.014989</b>	<b>0.018316</b>
	<b>0.5</b>	131	0.014954	0.021114
	<b>0.9</b>	166	0.014977	0.019388
<b>0.9</b>	<b>0.1</b>	79	0.014937	0.021426
	<b>0.5</b>	88	0.014943	0.019977
	<b>0.9</b>	57	0.014834	0.020392
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	988	0.014995	0.024702
	<b>0.5</b>	1109	0.014995	0.023603
	<b>0.9</b>	995	0.014996	0.021576
<b>0.5</b>	<b>0.1</b>	200	0.014986	0.026902
	<b>0.5</b>	218	0.014998	0.023828
	<b>0.9</b>	250	0.014979	0.022129
<b>0.9</b>	<b>0.1</b>	145	0.014989	0.024680
	<b>0.5</b>	129	0.015000	0.022829
	<b>0.9</b>	64	0.013993	0.021486
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1185	0.014996	0.027359
	<b>0.5</b>	1354	0.014997	0.021907
	<b>0.9</b>	1826	0.014998	0.022761
<b>0.5</b>	<b>0.1</b>	187	0.014998	0.021653
	<b>0.5</b>	234	0.014986	0.019969
	<b>0.9</b>	134	0.014986	0.019899
<b>0.9</b>	<b>0.1</b>	138	0.014973	0.022475
	<b>0.5</b>	138	0.014972	0.021767
	<b>0.9</b>	99	0.014991	0.026946

**Jadual 6.5(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Ldg. Simpang Renggam Daerah Kluang

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	72	0.014846	0.021744
	<b>0.5</b>	72	0.014911	0.019399
	<b>0.9</b>	86	0.014919	0.020022
<b>0.5</b>	<b>0.1</b>	44	0.014844	0.019616
	<b>0.5</b>	53	0.014710	0.019751
	<b>0.9</b>	61	0.014848	0.022966
<b>0.9</b>	<b>0.1</b>	50	0.014994	0.019464
	<b>0.5</b>	42	0.014925	0.022868
	<b>0.9</b>	61	0.014912	0.020685

<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	195	0.014952	0.021113
	<b>0.5</b>	78	0.014937	0.021128
	<b>0.9</b>	92	0.014797	0.021390
<b>0.5</b>	<b>0.1</b>	247	0.014812	0.022698
	<b>0.5</b>	86	0.014939	0.022154
	<b>0.9</b>	65	0.014993	0.021560
<b>0.9</b>	<b>0.1</b>	172	0.014892	0.022082
	<b>0.5</b>	88	0.014937	0.020355
	<b>0.9</b>	83	0.014940	0.023095
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	123	0.014934	0.021147
	<b>0.5</b>	92	0.014918	0.019883
	<b>0.9</b>	103	0.014801	0.020648
<b>0.5</b>	<b>0.1</b>	129	0.014928	0.023783
	<b>0.5</b>	89	0.014948	0.025262
	<b>0.9</b>	74	0.014882	0.027094
<b>0.9</b>	<b>0.1</b>	109	0.014955	0.024639
	<b>0.5</b>	85	0.014947	0.027360
	<b>0.9</b>	76	0.014897	0.023735

Berpandukan kepada Jadual 6.5(i), Jadual 6.5(ii) dan Jadual 6.5(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Simpang Renggam Daerah Kluang ialah 0.018316. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.5(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran Q1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.5(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.5 dan 0.1. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.5(iv) : Model rangkaian yang terbaik bagi Stesen Ldg. Simpang Renggam Daerah Kluang**

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi : 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.5	0.1	150	0.018316	3.6 3.3 5.2 3.8 2.2

Merujuk kepada Lampiran Q2, didapati bahawa sebanyak 150 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran Q3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran Q4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada kelima-lima hari dengan merujuk nilai hasil ramalan hujan pada Jadual 6.5(iv) di atas.

### 6.3.6 Stesen Ldg. Ulu Paloh Daerah Kluang

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.6(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.6(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.6(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.6(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Ulu Paloh Daerah Kluang

<b>Fungsi Pembelajaran : <i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	823	0.009992	0.011425
<b>0.5</b>	75	0.009960	0.010484
<b>0.9</b>	114	0.009901	0.013004
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>

<b>0.1</b>	996	0.009998	0.013444
<b>0.5</b>	168	0.009984	0.013325
<b>0.9</b>	144	0.009980	0.012359
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1140	0.009999	0.011703
<b>0.5</b>	298	0.009999	0.012319
<b>0.9</b>	143	0.009943	0.015502

**Jadual 6.6(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Ulu Paloh Daerah Kluang

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	476	0.010000	0.012173
	<b>0.5</b>	<b>609</b>	<b>0.009997</b>	<b>0.010042</b>
	<b>0.9</b>	720	0.009996	0.011083
<b>0.5</b>	<b>0.1</b>	152	0.009986	0.012798
	<b>0.5</b>	139	0.009966	0.010934
	<b>0.9</b>	182	0.009955	0.011995
<b>0.9</b>	<b>0.1</b>	84	0.009987	0.012579
	<b>0.5</b>	82	0.009942	0.013244
	<b>0.9</b>	57	0.009561	0.014432
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1028	0.009995	0.013051
	<b>0.5</b>	1189	0.009993	0.012849
	<b>0.9</b>	1107	0.009994	0.013125
<b>0.5</b>	<b>0.1</b>	225	0.009973	0.011949
	<b>0.5</b>	253	0.009978	0.011152
	<b>0.9</b>	223	0.009995	0.012146
<b>0.9</b>	<b>0.1</b>	145	0.009981	0.012910
	<b>0.5</b>	141	0.009998	0.012224
	<b>0.9</b>	54	0.009542	0.011626
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1291	0.009998	0.013768
	<b>0.5</b>	1143	0.009999	0.012078
	<b>0.9</b>	1737	0.009998	0.013564
<b>0.5</b>	<b>0.1</b>	211	0.009975	0.011237
	<b>0.5</b>	235	0.009978	0.012542
	<b>0.9</b>	124	0.009995	0.013115
<b>0.9</b>	<b>0.1</b>	139	0.009973	0.013051
	<b>0.5</b>	148	0.009970	0.014934
	<b>0.9</b>	100	0.009827	0.012677

**Jadual 6.6(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ldg. Ulu Paloh Daerah Kluang

<b>Fungsi Pembelajaran : TRAINIDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	74	0.009925	0.011995
	<b>0.5</b>	73	0.009945	0.011077
	<b>0.9</b>	88	0.009869	0.011135
<b>0.5</b>	<b>0.1</b>	45	0.009970	0.011009
	<b>0.5</b>	52	0.009796	0.012049
	<b>0.9</b>	62	0.009700	0.011796
<b>0.9</b>	<b>0.1</b>	57	0.009915	0.011622
	<b>0.5</b>	45	0.009764	0.011364
	<b>0.9</b>	65	0.009735	0.011229
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	210	0.009937	0.010332
	<b>0.5</b>	79	0.009765	0.013791
	<b>0.9</b>	95	0.009587	0.012424
<b>0.5</b>	<b>0.1</b>	242	0.009970	0.011773
	<b>0.5</b>	84	0.009998	0.011998
	<b>0.9</b>	65	0.009953	0.012295
<b>0.9</b>	<b>0.1</b>	175	0.009760	0.012928
	<b>0.5</b>	93	0.009973	0.013936
	<b>0.9</b>	83	0.009927	0.012555
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	139	0.009971	0.012592
	<b>0.5</b>	93	0.009945	0.012511
	<b>0.9</b>	104	0.009886	0.014087
<b>0.5</b>	<b>0.1</b>	144	0.009969	0.012814
	<b>0.5</b>	89	0.009937	0.012174
	<b>0.9</b>	78	0.009904	0.013935
<b>0.9</b>	<b>0.1</b>	129	0.009993	0.013895
	<b>0.5</b>	98	0.009920	0.013842
	<b>0.9</b>	76	0.009670	0.012430



Berpandukan kepada Jadual 6.6(i), Jadual 6.6(ii) dan Jadual 6.6(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Ulu Paloh Daerah Kluang ialah 0.010042. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.6(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran R1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.6(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.6(iv) : Model rangkaian yang terbaik bagi Stesen Ldg. Ulu Paloh Daerah Kluang**

<b>Fungsi Pembelajaran : <i>TRAININGDM</i></b>				
<b>Nod Tersembunyi : 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.1	0.5	609	0.010042	2.6 15.2 0.0 11.7 5.0

Merujuk kepada Lampiran R2, didapati bahawa sebanyak 609 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran R3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran R4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, keempat dan kelima, manakala hari ketiga tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.6(iv) di atas.

### **6.3.7 Stesen Ldg. Getah Malaya Daerah Kota Tinggi**

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 100 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.7(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.7(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.7(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 100.

**Jadual 6.7(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Getah Malaya Daerah Kota Tinggi

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	751	0.009992	0.015556
<b>0.5</b>	61	0.009980	0.019300
<b>0.9</b>	117	0.009873	0.014876
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	923	0.009992	0.016745
<b>0.5</b>	236	0.009995	0.020216
<b>0.9</b>	121	0.009991	0.020879
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1031	0.009991	0.022094
<b>0.5</b>	254	0.009982	0.020364
<b>0.9</b>	120	0.009981	0.017387

**Jadual 6.7(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Getah Malaya Daerah Kota Tinggi

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>

<b>0.1</b>	<b>0.1</b>	453	0.009999	0.017075
	<b>0.5</b>	513	0.009994	0.022790
	<b>0.9</b>	<b>724</b>	<b>0.009994</b>	<b>0.013507</b>
<b>0.5</b>	<b>0.1</b>	146	0.009981	0.014672
	<b>0.5</b>	128	0.009958	0.017224
	<b>0.9</b>	151	0.009956	0.015357
<b>0.9</b>	<b>0.1</b>	76	0.009986	0.016179
	<b>0.5</b>	85	0.009981	0.016908
	<b>0.9</b>	57	0.009749	0.018359
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	872	0.009990	0.023603
	<b>0.5</b>	1039	0.009998	0.021067
	<b>0.9</b>	873	0.009995	0.022183
<b>0.5</b>	<b>0.1</b>	184	0.009993	0.026666
	<b>0.5</b>	238	0.009988	0.014663
	<b>0.9</b>	247	0.009979	0.015073
<b>0.9</b>	<b>0.1</b>	134	0.009966	0.021559
	<b>0.5</b>	118	0.009947	0.017676
	<b>0.9</b>	64	0.009489	0.015378
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1267	0.009998	0.027776
	<b>0.5</b>	1331	0.010000	0.023799
	<b>0.9</b>	1727	0.009998	0.019541
<b>0.5</b>	<b>0.1</b>	173	0.009994	0.020012
	<b>0.5</b>	211	0.009994	0.015805
	<b>0.9</b>	130	0.009977	0.021592
<b>0.9</b>	<b>0.1</b>	120	0.009999	0.024334
	<b>0.5</b>	139	0.009988	0.019909
	<b>0.9</b>	99	0.009893	0.023603

**Jadual 6.7(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Ldg. Getah Malaya Daerah Kota Tinggi

<b>Fungsi Pembelajaran :TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	71	0.009855	0.017227
	<b>0.5</b>	72	0.009935	0.014086
	<b>0.9</b>	86	0.009935	0.015086
<b>0.5</b>	<b>0.1</b>	43	0.009847	0.018449
	<b>0.5</b>	51	0.009631	0.014207
	<b>0.9</b>	60	0.009750	0.018495

<b>0.9</b>	<b>0.1</b>	48	0.009940	0.015343
	<b>0.5</b>	44	0.009807	0.018229
	<b>0.9</b>	61	0.009903	0.015067
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	169	0.009953	0.018104
	<b>0.5</b>	78	0.009711	0.015487
	<b>0.9</b>	90	0.009953	0.016943
<b>0.5</b>	<b>0.1</b>	225	0.009832	0.018907
	<b>0.5</b>	69	0.009939	0.022142
	<b>0.9</b>	65	0.009771	0.014771
<b>0.9</b>	<b>0.1</b>	160	0.009831	0.021057
	<b>0.5</b>	80	0.009982	0.015196
	<b>0.9</b>	85	0.009852	0.018245
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	117	0.009997	0.020584
	<b>0.5</b>	91	0.009932	0.016733
	<b>0.9</b>	98	0.009926	0.020780
<b>0.5</b>	<b>0.1</b>	153	0.009969	0.020727
	<b>0.5</b>	75	0.009940	0.020058
	<b>0.9</b>	74	0.009998	0.026537
<b>0.9</b>	<b>0.1</b>	119	0.009985	0.023932
	<b>0.5</b>	88	0.009950	0.024277
	<b>0.9</b>	74	0.009939	0.023339

Berpandukan kepada Jadual 6.7(i), Jadual 6.7(ii) dan Jadual 6.7(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Getah Malaya Daerah Kota Tinggi ialah 0.013507. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.7(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran S1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.7(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.9. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.7(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Getah Malaya Daerah Kota Tinggi

Fungsi Pembelajaran : <i>TRAINGDM</i>				
Nod Tersembunyi : 7				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
0.1	0.9	724	0.013507	11.3 0.0 26.8 2.9 13.9

Merujuk kepada Lampiran S2, didapati bahawa sebanyak 724 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran S3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran S4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, ketiga, keempat dan kelima, manakala hari kedua tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.7(iv) di atas.

### 6.3.8 Model Terbaik bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi

Dengan terlaksananya kod arahan-arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.8(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.8(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.8(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.015, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.8(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi

<b>Fungsi Pembelajaran : <i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1158	0.015000	0.008193
<b>0.5</b>	<b>122</b>	<b>0.014990</b>	<b>0.007447</b>
<b>0.9</b>	128	0.014996	0.008225
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1309	0.014998	0.008358
<b>0.5</b>	323	0.014991	0.008743
<b>0.9</b>	195	0.014989	0.008648
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1242	0.014994	0.008731
<b>0.5</b>	462	0.014996	0.008390
<b>0.9</b>	165	0.014993	0.009062

**Jadual 6.8(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainngdm* bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi

<b>Fungsi Pembelajaran : <i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	909	0.014995	0.007652
	<b>0.5</b>	1002	0.015000	0.007990
	<b>0.9</b>	925	0.014997	0.007996
<b>0.5</b>	<b>0.1</b>	185	0.014984	0.008800
	<b>0.5</b>	194	0.014985	0.007910
	<b>0.9</b>	211	0.014963	0.008451
<b>0.9</b>	<b>0.1</b>	103	0.014980	0.008431
	<b>0.5</b>	103	0.014983	0.008645
	<b>0.9</b>	80	0.014797	0.007880
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1152	0.014996	0.008572
	<b>0.5</b>	1319	0.014998	0.008745
	<b>0.9</b>	1268	0.014999	0.008181
<b>0.5</b>	<b>0.1</b>	326	0.014997	0.009631
	<b>0.5</b>	302	0.014991	0.008667
	<b>0.9</b>	371	0.014998	0.007718
<b>0.9</b>	<b>0.1</b>	171	0.014961	0.009961
	<b>0.5</b>	173	0.014993	0.009092
	<b>0.9</b>	83	0.014723	0.008068
<b>Nod Tersembunyi = 15</b>				

Alfa (lr)	Beta (mc)	Lelaran	MSE(Latihan)	MSE(Validasi)
0.1	0.1	1646	0.014998	0.010111
	0.5	1820	0.014998	0.008773
	0.9	2340	0.015000	0.008328
0.5	0.1	249	0.014999	0.009324
	0.5	317	0.014990	0.007841
	0.9	260	0.014992	0.007784
0.9	0.1	216	0.014988	0.008708
	0.5	176	0.014968	0.009525
	0.9	130	0.014980	0.008648

**Jadual 6.8(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	79	0.014938	0.008455
	0.5	77	0.014838	0.008016
	0.9	91	0.014896	0.007969
0.5	0.1	66	0.014971	0.008319
	0.5	54	0.014889	0.008865
	0.9	70	0.014779	0.007700
0.9	0.1	71	0.014838	0.008673
	0.5	48	0.014774	0.008851
	0.9	69	0.014819	0.008123
<b>Nod Tersembunyi = 14</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	252	0.014972	0.009262
	0.5	83	0.014965	0.008876
	0.9	105	0.014858	0.008345
0.5	0.1	248	0.014974	0.009405
	0.5	117	0.014986	0.007772
	0.9	69	0.014886	0.008573
0.9	0.1	262	0.014971	0.009457
	0.5	100	0.014956	0.008317
	0.9	93	0.014933	0.008562
<b>Nod Tersembunyi = 15</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	182	0.014941	0.008134
	0.5	108	0.014956	0.008828
	0.9	107	0.014905	0.008963
0.5	0.1	190	0.014881	0.008912
	0.5	112	0.014961	0.009584
	0.9	80	0.014841	0.010086

<b>0.9</b>	<b>0.1</b>	207	0.014998	0.008855
	<b>0.5</b>	123	0.014954	0.009589
	<b>0.9</b>	82	0.014854	0.009457

Berpandukan kepada Jadual 6.8(i), Jadual 6.8(ii) dan Jadual 6.8(iii), didapati ralat validasi terkecil bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi ialah 0.007447. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.8(i). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran T1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.8(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran ialah 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingd* sebagai fungsi pembelajaran.

**Jadual 6.8(iv) :** Model rangkaian yang terbaik bagi Stesen Rancangan Ulu Sebol Daerah Kota Tinggi

<b>Fungsi Pembelajaran : TRAINGD</b>			
<b>Nod Tersembunyi : 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.5	122	0.007447	9.6 15.0 0.0 8.4 11.5

Merujuk kepada Lampiran T2, didapati bahawa sebanyak 122 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran T3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran T4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.



Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, keempat dan kelima, manakala hari ketiga tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.8(iv) di atas.

### 6.3.9 Stesen Ibu Bekalan Kahang Daerah Mersing

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.9(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.9(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.9(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.9(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ibu Bekalan Kahang Daerah Mersing.

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1423	0.014998	0.013688
<b>0.5</b>	116	0.014993	0.013606
<b>0.9</b>	139	0.014978	0.014122
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1937	0.014999	0.013920

<b>0.5</b>	370	0.014994	0.014003
<b>0.9</b>	245	0.014998	0.014937
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2069	0.014998	0.014605
<b>0.5</b>	481	0.014998	0.014065
<b>0.9</b>	264	0.014992	0.013782

**Jadual 6.9(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainngdm* bagi Stesen Ibu Bekalan Kahang Daerah Mersing

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	943	0.014997	0.013742
	<b>0.5</b>	649	0.015000	0.014458
	<b>0.9</b>	1019	0.014999	0.014425
<b>0.5</b>	<b>0.1</b>	288	0.014998	0.013728
	<b>0.5</b>	238	0.014992	0.013869
	<b>0.9</b>	295	0.014999	0.014123
<b>0.9</b>	<b>0.1</b>	154	0.014980	0.014446
	<b>0.5</b>	154	0.014986	0.013788
	<b>0.9</b>	111	0.014986	0.013819
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1662	0.014998	0.014565
	<b>0.5</b>	2042	0.015000	0.014305
	<b>0.9</b>	1864	0.015000	0.014910
<b>0.5</b>	<b>0.1</b>	395	0.014997	0.015184
	<b>0.5</b>	384	0.014997	0.014431
	<b>0.9</b>	416	0.014993	0.014369
<b>0.9</b>	<b>0.1</b>	222	0.014997	0.014367
	<b>0.5</b>	236	0.015000	0.014432
	<b>0.9</b>	110	0.014914	0.013529
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	2526	0.015000	0.014821
	<b>0.5</b>	2278	0.015000	0.013662
	<b>0.9</b>	2895	0.015000	0.015027
<b>0.5</b>	<b>0.1</b>	365	0.014992	0.014448
	<b>0.5</b>	412	0.014996	0.014683

	<b>0.9</b>	216	0.015000	0.014409
<b>0.9</b>	<b>0.1</b>	234	0.014996	0.015373
	<b>0.5</b>	250	0.014990	0.014766
	<b>0.9</b>	223	0.014988	0.013337

**Jadual 6.9(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ibu Bekalan Kahang Daerah Mersing

<b>Fungsi Pembelajaran : TRAINIDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	85	0.014881	0.014576
	<b>0.5</b>	82	0.014883	0.014455
	<b>0.9</b>	98	0.014949	0.014710
<b>0.5</b>	<b>0.1</b>	97	0.014933	0.014298
	<b>0.5</b>	62	0.014885	0.014043
	<b>0.9</b>	73	0.014990	0.013998
<b>0.9</b>	<b>0.1</b>	115	0.014952	0.013488
	<b>0.5</b>	57	0.014998	0.013499
	<b>0.9</b>	80	0.014895	0.013625
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	396	0.014989	0.013330
	<b>0.5</b>	109	0.014963	0.014193
	<b>0.9</b>	<b>110</b>	<b>0.014859</b>	<b>0.013242</b>
<b>0.5</b>	<b>0.1</b>	381	0.014967	0.014194
	<b>0.5</b>	145	0.014999	0.013987
	<b>0.9</b>	80	0.014810	0.013810
<b>0.9</b>	<b>0.1</b>	341	0.014942	0.013907
	<b>0.5</b>	151	0.014991	0.014793
	<b>0.9</b>	187	0.014965	0.013429
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	236	0.014967	0.015077
	<b>0.5</b>	157	0.014993	0.015139
	<b>0.9</b>	116	0.014899	0.013948
<b>0.5</b>	<b>0.1</b>	208	0.014990	0.016035
	<b>0.5</b>	156	0.014984	0.013976

	<b>0.9</b>	90	0.014951	0.013925
<b>0.9</b>	<b>0.1</b>	201	0.014998	0.014083
	<b>0.5</b>	171	0.014988	0.014487
	<b>0.9</b>	91	0.014956	0.014491

Berpandukan kepada Jadual 6.9(i), Jadual 6.9(ii) dan Jadual 6.9(iii), didapati ralat validasi terkecil bagi Stesen Ibu Bekalan Kahang Daerah Mersing ialah 0.013242. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.9(iii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran U1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.9(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.9. Manakala nilai 14 adalah nilai bagi nod tersembunyi dan *traingdx* sebagai fungsi pembelajaran.

**Jadual 6.9(iv) :** Model rangkaian yang terbaik bagi Stesen Ibu Bekalan Kahang Daerah Mersing

<b>Fungsi Pembelajaran: <i>TRAIINGDX</i></b>				
<b>Nod Tersembunyi : 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.1	0.9	110	0.013242	9.1 5.8 9.2 3.7 0.0

Merujuk kepada Lampiran U2, didapati bahawa sebanyak 110 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran U3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran U4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, ketiga dan keempat, manakala hari kelima tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.9(iv) di atas.

### 6.3.10 Stesen Pusat Pertanian Endau Daerah Mersing

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.10(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.10(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.10(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.10(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Pusat Pertanian Endau Daerah Mersing

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2158	0.010000	0.012089
<b>0.5</b>	234	0.009994	0.011897
<b>0.9</b>	247	0.009999	0.012072
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2712	0.010000	0.012252
<b>0.5</b>	602	0.009999	0.012808
<b>0.9</b>	371	0.009996	0.013156
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	3076	0.010000	0.012986
<b>0.5</b>	693	0.010000	0.013189
<b>0.9</b>	317	0.009991	0.012697

**Jadual 6.10(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Pusat Pertanian Endau Daerah Mersing

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>			
<b>Nod Tersembunyi = 7</b>			

Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	1370	0.009999	0.012709
	0.5	1700	0.010000	0.013221
	0.9	1915	0.010000	0.011676
0.5	0.1	391	0.010000	0.012636
	0.5	386	0.009997	0.013132
	0.9	434	0.009993	0.012023
0.9	0.1	245	0.009999	0.013015
	0.5	<b>263</b>	<b>0.009999</b>	<b>0.011371</b>
	0.9	197	0.009996	0.012837
<b>Nod Tersembunyi = 14</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	2147	0.009999	0.012191
	0.5	3041	0.010000	0.011962
	0.9	2826	0.009999	0.012577
0.5	0.1	606	0.009997	0.014058
	0.5	604	0.009998	0.012509
	0.9	751	0.009997	0.012494
0.9	0.1	385	0.009998	0.012606
	0.5	274	0.009995	0.014109
	0.9	222	0.009997	0.011811
<b>Nod Tersembunyi = 15</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE(Latihan)	MSE(Validasi)
0.1	0.1	3646	0.010000	0.014670
	0.5	4095	0.010000	0.012392
	0.9	4962	0.010000	0.012761
0.5	0.1	505	0.009999	0.014011
	0.5	519	0.009998	0.012299
	0.9	347	0.010000	0.013109
0.9	0.1	403	0.009998	0.012791
	0.5	433	0.009996	0.012830
	0.9	345	0.009997	0.012348

**Jadual 6.10(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Pusat Pertanian Endau Daerah Mersing

<b>Fungsi Pembelajaran : <i>TRAINIDX</i></b>				
<b>Nod Tersembunyi = 7</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	117	0.009984	0.012385
	0.5	95	0.009933	0.011781
	0.9	106	0.009963	0.012423
0.5	0.1	147	0.009893	0.012896
	0.5	72	0.009909	0.011452

	<b>0.9</b>	80	0.009999	0.012565
<b>0.9</b>	<b>0.1</b>	159	0.009971	0.012328
	<b>0.5</b>	86	0.009973	0.012254
	<b>0.9</b>	89	0.009919	0.012582
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	471	0.009984	0.012526
	<b>0.5</b>	145	0.009981	0.012260
	<b>0.9</b>	117	0.009994	0.012214
<b>0.5</b>	<b>0.1</b>	581	0.009974	0.012725
	<b>0.5</b>	181	0.009989	0.012563
	<b>0.9</b>	85	0.009995	0.012220
<b>0.9</b>	<b>0.1</b>	519	0.009991	0.012447
	<b>0.5</b>	222	0.009991	0.011991
	<b>0.9</b>	204	0.009988	0.013852
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	383	0.009996	0.012041
	<b>0.5</b>	228	0.009993	0.012223
	<b>0.9</b>	176	0.009998	0.012747
<b>0.5</b>	<b>0.1</b>	498	0.009925	0.013059
	<b>0.5</b>	217	0.009993	0.013733
	<b>0.9</b>	173	0.009980	0.012937
<b>0.9</b>	<b>0.1</b>	418	0.009966	0.012310
	<b>0.5</b>	240	0.009980	0.014141
	<b>0.9</b>	147	0.009995	0.012185

Berpandukan kepada Jadual 6.10(i), Jadual 6.10(ii) dan Jadual 6.10(iii), didapati ralat validasi terkecil bagi Stesen Pusat Pertanian Endau Daerah Mersing ialah 0.011371. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.10(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran V1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.10(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.9 dan 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.10(iv) :** Model rangkaian yang terbaik bagi Stesen Pusat Pertanian Endau Daerah Mersing

Fungsi Pembelajaran : <i>TRAINGDM</i>				
Nod Tersembunyi : 7				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
0.9	0.5	263	0.011371	10.1 15.3 8.9 11.9 16.9

Merujuk kepada Lampiran V2, didapati bahawa sebanyak 263 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran V3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran V4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada kelima-lima hari dengan merujuk nilai hasil ramalan hujan pada Jadual 6.10(iv) di atas.

### 6.3.11 Stesen Ldg. Temiang Renchong Daerah Muar

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.11(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.11(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.11(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.03, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.11(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Temiang Renchong Daerah Muar.



<b>Fungsi Pembelajaran : <i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1403	0.030000	0.036973
<b>0.5</b>	227	0.029989	0.038874
<b>0.9</b>	159	0.029982	0.039946
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2122	0.030000	0.042178
<b>0.5</b>	522	0.029997	0.040554
<b>0.9</b>	310	0.029989	0.038418
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1599	0.029999	0.039327
<b>0.5</b>	529	0.029995	0.046840
<b>0.9</b>	156	0.029995	0.040710

**Jadual 6.11(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Temiang Renchong Daerah Muar

<b>Fungsi Pembelajaran : <i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1009	0.029999	0.039838
	<b>0.5</b>	1761	0.029999	0.037086
	<b>0.9</b>	1133	0.029996	0.037927
<b>0.5</b>	<b>0.1</b>	366	0.029990	0.037448
	<b>0.5</b>	277	0.029997	0.036854
	<b>0.9</b>	157	0.029985	0.038550
<b>0.9</b>	<b>0.1</b>	127	0.029994	0.037918
	<b>0.5</b>	135	0.029976	0.039530
	<b>0.9</b>	112	0.029992	0.041218
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1765	0.030000	0.041375
	<b>0.5</b>	2199	0.030000	0.041186
	<b>0.9</b>	1472	0.029998	0.042871
<b>0.5</b>	<b>0.1</b>	465	0.029997	0.039698
	<b>0.5</b>	360	0.029998	0.039702
	<b>0.9</b>	434	0.029993	0.039183
<b>0.9</b>	<b>0.1</b>	237	0.029982	0.041613
	<b>0.5</b>	310	0.029992	0.038805
	<b>0.9</b>	179	0.029995	0.042937
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>

<b>0.1</b>	<b>0.1</b>	2392	0.029998	0.042156
	<b>0.5</b>	2671	0.029999	0.041751
	<b>0.9</b>	2349	0.029999	0.041019
<b>0.5</b>	<b>0.1</b>	386	0.029997	0.039505
	<b>0.5</b>	424	0.029993	0.038326
	<b>0.9</b>	534	0.029996	0.043757
<b>0.9</b>	<b>0.1</b>	304	0.029991	0.042272
	<b>0.5</b>	309	0.029995	0.039363
	<b>0.9</b>	254	0.029997	0.040319

**Jadual 6.11(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ldg. Temiang Renchong Daerah Muar

<b>Fungsi Pembelajaran : TRAINIDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	83	0.029996	0.038737
	<b>0.5</b>	<b>88</b>	<b>0.029755</b>	<b>0.036014</b>
	<b>0.9</b>	97	0.029954	0.038073
<b>0.5</b>	<b>0.1</b>	121	0.029064	0.037532
	<b>0.5</b>	57	0.029943	0.036854
	<b>0.9</b>	71	0.029767	0.040527
<b>0.9</b>	<b>0.1</b>	110	0.029961	0.038718
	<b>0.5</b>	55	0.029817	0.036782
	<b>0.9</b>	69	0.029908	0.040022
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	368	0.029947	0.039995
	<b>0.5</b>	139	0.029990	0.039857
	<b>0.9</b>	109	0.029825	0.039466
<b>0.5</b>	<b>0.1</b>	315	0.029781	0.039150
	<b>0.5</b>	108	0.029993	0.049304
	<b>0.9</b>	75	0.029876	0.039970
<b>0.9</b>	<b>0.1</b>	374	0.029863	0.040604
	<b>0.5</b>	140	0.029962	0.037738
	<b>0.9</b>	93	0.029861	0.039567
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	248	0.029913	0.039087
	<b>0.5</b>	176	0.029980	0.040488
	<b>0.9</b>	112	0.029989	0.044251
<b>0.5</b>	<b>0.1</b>	388	0.029993	0.042911
	<b>0.5</b>	138	0.029987	0.044485
	<b>0.9</b>	85	0.029930	0.041047

0.9	0.1	367	0.029960	0.044783
	0.5	199	0.030000	0.041293
	0.9	96	0.029839	0.041095

Berpandukan kepada Jadual 6.11(i), Jadual 6.11(ii) dan Jadual 6.11(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Temiang Renchong Daerah Muar ialah 0.036014. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.11(iii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran W1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.11(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdx* sebagai fungsi pembelajaran.

**Jadual 6.11(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Temiang Renchong Daerah Muar

Fungsi Pembelajaran : <i>TRAINGDX</i>				
Nod Tersembunyi : 7				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
0.1	0.5	88	0.036014	7.4 11.8 15.3 0.0 2.5

Merujuk kepada Lampiran W2, didapati bahawa sebanyak 88 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran W3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran W4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, ketiga dan kelima, manakala hari keempat tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.11(iv) di atas.

### 6.3.12 Stesen Ldg. Gomali Batu Enam Daerah Muar

Dengan terlaksananya kod arahan-arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat akan terpapar. Jadual 6.12(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.12(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.12(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.025, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.12(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Gomali Batu Enam Daerah Muar

<b>Fungsi Pembelajaran : TRAINGD</b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1071	0.024998	0.012847
<b>0.5</b>	<b>116</b>	<b>0.024985</b>	<b>0.010529</b>
<b>0.9</b>	130	0.024979	0.011733
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1186	0.024997	0.012646
<b>0.5</b>	244	0.024994	0.011262
<b>0.9</b>	198	0.024984	0.011285
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1397	0.024997	0.011641
<b>0.5</b>	373	0.024992	0.011432
<b>0.9</b>	164	0.024984	0.012067

**Jadual 6.12(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi

Stesen Ldg. Gomali Batu Enam Daerah Muar

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	713	0.024998	0.011808
	<b>0.5</b>	820	0.024998	0.011410
	<b>0.9</b>	1003	0.024999	0.010734
<b>0.5</b>	<b>0.1</b>	207	0.024997	0.011768
	<b>0.5</b>	184	0.024984	0.010874
	<b>0.9</b>	211	0.024979	0.011472
<b>0.9</b>	<b>0.1</b>	107	0.024961	0.011956
	<b>0.5</b>	103	0.024992	0.013836
	<b>0.9</b>	80	0.024797	0.011464
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1181	0.024998	0.011008
	<b>0.5</b>	1354	0.024996	0.011922
	<b>0.9</b>	1269	0.024998	0.011521
<b>0.5</b>	<b>0.1</b>	259	0.024991	0.012137
	<b>0.5</b>	289	0.024994	0.010981
	<b>0.9</b>	289	0.024984	0.012275
<b>0.9</b>	<b>0.1</b>	182	0.024990	0.011788
	<b>0.5</b>	163	0.024973	0.011579
	<b>0.9</b>	102	0.024922	0.011429
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1708	0.024999	0.012629
	<b>0.5</b>	1577	0.025000	0.012950
	<b>0.9</b>	2547	0.024999	0.011118
<b>0.5</b>	<b>0.1</b>	249	0.024997	0.012798
	<b>0.5</b>	282	0.024998	0.012551
	<b>0.9</b>	193	0.024999	0.011398
<b>0.9</b>	<b>0.1</b>	193	0.024985	0.011760
	<b>0.5</b>	183	0.024976	0.012483
	<b>0.9</b>	140	0.024972	0.010972

**Jadual 6.12(iii)** : Model rangkaian menggunakan fungsi pembelajaran *Trainindx* bagi Stesen Ldg. Gomali Batu Enam Daerah Muar

<b>Fungsi Pembelajaran :<i>TRAINGDx</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>

<b>0.1</b>	<b>0.1</b>	83	0.024962	0.011806
	<b>0.5</b>	80	0.024965	0.011857
	<b>0.9</b>	92	0.024802	0.012291
<b>0.5</b>	<b>0.1</b>	106	0.024146	0.013118
	<b>0.5</b>	58	0.024837	0.011742
	<b>0.9</b>	68	0.024825	0.011839
<b>0.9</b>	<b>0.1</b>	83	0.024690	0.011961
	<b>0.5</b>	50	0.024883	0.011556
	<b>0.9</b>	69	0.024891	0.011193
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	247	0.024977	0.013574
	<b>0.5</b>	84	0.024861	0.012592
	<b>0.9</b>	99	0.024922	0.011712
<b>0.5</b>	<b>0.1</b>	336	0.024809	0.011857
	<b>0.5</b>	102	0.024993	0.011330
	<b>0.9</b>	71	0.024984	0.010957
<b>0.9</b>	<b>0.1</b>	232	0.024704	0.012079
	<b>0.5</b>	105	0.024951	0.012287
	<b>0.9</b>	90	0.024975	0.011285
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	174	0.024981	0.011910
	<b>0.5</b>	102	0.024994	0.014175
	<b>0.9</b>	103	0.024851	0.013570
<b>0.5</b>	<b>0.1</b>	168	0.024970	0.012841
	<b>0.5</b>	117	0.024974	0.012148
	<b>0.9</b>	82	0.024938	0.011570
<b>0.9</b>	<b>0.1</b>	207	0.024849	0.011491
	<b>0.5</b>	122	0.024982	0.011693
	<b>0.9</b>	81	0.024908	0.012487

Berpandukan kepada Jadual 6.12(i), Jadual 6.12(ii) dan Jadual 6.12(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Gomali Batu Enam Daerah Muar ialah 0.010529. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.12(i). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran X1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.12(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran ialah 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingd* sebagai fungsi pembelajaran.

**Jadual 6.12(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Gomali Batu Enam  
Daerah Muar

<b>Fungsi Pembelajaran : <i>TRAINGD</i></b>			
<b>Nod Tersembunyi : 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.5	116	0.010529	5.3 9.3 0.0 9.3 16.1

Merujuk kepada Lampiran X2, didapati bahawa sebanyak 116 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran X3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran X4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, keempat dan kelima, manakala hari ketiga tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.12(iv) di atas.

### **6.3.13 Stesen Ldg. Getah Kukup Daerah Pontian**

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.13(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.13(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.13(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.13(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Getah Kukup Daerah Pontian

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1721	0.010000	0.010689
<b>0.5</b>	132	0.009999	0.009690
<b>0.9</b>	188	0.009994	0.009656
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2667	0.009999	0.010077
<b>0.5</b>	368	0.009999	0.010096
<b>0.9</b>	279	0.009992	0.010769
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2567	0.010000	0.010325
<b>0.5</b>	568	0.010000	0.009882
<b>0.9</b>	321	0.009996	0.010291

**Jadual 6.13(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Getah Kukup Daerah Pontian

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1095	0.009999	0.010181
	<b>0.5</b>	483	0.009998	0.010581
	<b>0.9</b>	1180	0.009999	0.010887



0.5	0.1	308	0.009993	0.010746
	0.5	291	0.010000	0.009641
	0.9	433	0.009995	0.010626
0.9	0.1	198	0.009991	0.010593
	0.5	197	0.009994	0.010426
	0.9	139	0.009997	0.010039
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
0.1	0.1	2317	0.009999	0.010213
	0.5	2637	0.009999	0.010295
	0.9	2523	0.010000	0.009994
0.5	0.1	469	0.009999	0.010689
	0.5	502	0.009997	0.009485
	0.9	558	0.009999	0.010030
0.9	0.1	310	0.009995	0.010016
	0.5	270	0.009999	0.009873
	0.9	101	0.009962	0.009385
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
0.1	0.1	2777	0.009999	0.010701
	0.5	2613	0.009999	0.009994
	0.9	3503	0.009999	0.011278
0.5	0.1	441	0.009996	0.010506
	0.5	449	0.009997	0.010445
	0.9	254	0.009994	0.010088
0.9	0.1	269	0.009996	0.010962
	0.5	342	0.009992	0.010259
	0.9	<b>254</b>	<b>0.009994</b>	<b>0.009054</b>

**Jadual 6.13(iii)** : Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Ldg. Getah Kukup Daerah Pontian

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
0.1	0.1	87	0.009926	0.010290
	0.5	84	0.009946	0.010464
	0.9	102	0.009869	0.011229
0.5	0.1	129	0.009931	0.010595
	0.5	68	0.009928	0.009791
	0.9	78	0.009988	0.010085
0.9	0.1	141	0.009947	0.010254
	0.5	54	0.009925	0.010555
	0.9	86	0.009890	0.009908

<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	465	0.010000	0.010340
	<b>0.5</b>	128	0.009964	0.010769
	<b>0.9</b>	115	0.009840	0.010078
<b>0.5</b>	<b>0.1</b>	508	0.009954	0.010317
	<b>0.5</b>	167	0.009995	0.009875
	<b>0.9</b>	83	0.009992	0.010022
<b>0.9</b>	<b>0.1</b>	419	0.009987	0.010553
	<b>0.5</b>	194	0.009992	0.010214
	<b>0.9</b>	179	0.009997	0.010134
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	285	0.009996	0.010533
	<b>0.5</b>	186	0.009969	0.011721
	<b>0.9</b>	124	0.009946	0.010909
<b>0.5</b>	<b>0.1</b>	305	0.009998	0.011153
	<b>0.5</b>	194	0.009989	0.009499
	<b>0.9</b>	89	0.009967	0.010219
<b>0.9</b>	<b>0.1</b>	234	0.009901	0.009735
	<b>0.5</b>	190	0.009990	0.010365
	<b>0.9</b>	119	0.009962	0.009802

Berpandukan kepada Jadual 6.13(i), Jadual 6.13(ii) dan Jadual 6.13(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Getah Kukup Daerah Pontian ialah 0.009054. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.13(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran Y1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.13(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.9 dan 0.9. Manakala nilai 15 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.13(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Getah Kukup Daerah Pontian

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi : 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>

0.9	0.9	254	0.009054	5.8	6.1	24.6	14.6	0.0
-----	-----	-----	----------	-----	-----	------	------	-----

Merujuk kepada Lampiran Y2, didapati bahawa sebanyak 254 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran Y3 menunjukkan graf pemadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran Y4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, kedua, ketiga dan keempat, manakala hari kelima tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.13(iv) di atas.

### 6.3.14 Stesen Pintu Pasang Surut Senggarang Daerah Pontian

Dengan terlaksananya kod arahan-arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.14(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.14(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.14(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.14(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Pintu Pasang Surut Senggarang Daerah Pontian

<b>Fungsi Pembelajaran : <i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>

<b>0.1</b>	1721	824	0.009995
<b>0.5</b>	132	25	0.009961
<b>0.9</b>	188	100	0.009979
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2667	1371	0.009995
<b>0.5</b>	368	93	0.009990
<b>0.9</b>	279	134	0.009970
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	2567	1233	0.009997
<b>0.5</b>	568	215	0.009993
<b>0.9</b>	321	153	0.009952

**Jadual 6.14 (ii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainngdm* bagi Stesen Pintu Pasang Surut Senggarang Daerah Pontian

<b>Fungsi Pembelajaran :TRAINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	386	0.009999	0.010469
	<b>0.5</b>	14	0.009993	0.010526
	<b>0.9</b>	434	0.009995	0.009993
<b>0.5</b>	<b>0.1</b>	151	0.009984	0.009860
	<b>0.5</b>	115	0.009992	0.009535
	<b>0.9</b>	224	0.009981	0.010256
<b>0.9</b>	<b>0.1</b>	81	0.009991	0.010586
	<b>0.5</b>	80	0.010000	0.010886
	<b>0.9</b>	35	0.009733	0.011259
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1229	0.009994	0.010572
	<b>0.5</b>	1371	0.009998	0.011830
	<b>0.9</b>	1237	0.009999	0.010693
<b>0.5</b>	<b>0.1</b>	223	0.009984	0.011117
	<b>0.5</b>	237	0.009985	0.011358
	<b>0.9</b>	208	0.009990	0.010634
<b>0.9</b>	<b>0.1</b>	123	0.009963	0.010794
	<b>0.5</b>	142	0.009998	0.010598
	<b>0.9</b>	54	0.009295	0.010790
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1260	0.009997	0.011220
	<b>0.5</b>	956	0.009996	0.010891
	<b>0.9</b>	1646	0.010000	0.010153
<b>0.5</b>	<b>0.1</b>	221	0.009980	0.010339
	<b>0.5</b>	212	0.009975	0.010875

	<b>0.9</b>	89	0.009983	0.011648
<b>0.9</b>	<b>0.1</b>	125	0.009959	0.010668
	<b>0.5</b>	159	0.009998	0.011544
	<b>0.9</b>	<b>82</b>	<b>0.009548</b>	<b>0.009309</b>

**Jadual 6.14(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Pintu Pasang Surut Senggarang Daerah Pontian

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	68	0.009881	0.010108
	<b>0.5</b>	70	0.009942	0.010841
	<b>0.9</b>	85	0.009883	0.010680
<b>0.5</b>	<b>0.1</b>	60	0.009261	0.010365
	<b>0.5</b>	49	0.009890	0.010465
	<b>0.9</b>	61	0.009922	0.010886
<b>0.9</b>	<b>0.1</b>	61	0.009947	0.009949
	<b>0.5</b>	35	0.009919	0.011344
	<b>0.9</b>	67	0.009852	0.010074
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	218	0.009994	0.011526
	<b>0.5</b>	81	0.009641	0.010552
	<b>0.9</b>	99	0.009701	0.009813
<b>0.5</b>	<b>0.1</b>	224	0.009931	0.011302
	<b>0.5</b>	82	0.009991	0.009858
	<b>0.9</b>	66	0.009863	0.010226
<b>0.9</b>	<b>0.1</b>	184	0.009995	0.010243
	<b>0.5</b>	100	0.009985	0.010679
	<b>0.9</b>	93	0.009946	0.012692
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	133	0.009822	0.010386
	<b>0.5</b>	98	0.009894	0.011374
	<b>0.9</b>	103	0.009734	0.010378
<b>0.5</b>	<b>0.1</b>	135	0.009964	0.011386
	<b>0.5</b>	90	0.009982	0.010768

	<b>0.9</b>	72	0.009935	0.010129
<b>0.9</b>	<b>0.1</b>	91	0.009774	0.009909
	<b>0.5</b>	94	0.009932	0.009945
	<b>0.9</b>	80	0.009921	0.010609

Berpandukan kepada Jadual 6.14(i), Jadual 6.14(ii) dan Jadual 6.14(iii), didapati ralat validasi terkecil bagi Stesen Pintu Pasang Surut Senggarang Daerah Pontian ialah 0.009309. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.14(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran Z1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.14(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.9 dan 0.9. Manakala nilai 15 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.14(iv) :** Model rangkaian yang terbaik bagi Stesen Pintu Pasang Surut Senggarang Daerah Pontian

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi : 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.9	0.9	82	0.009309	3.5 10.0 11.7 1.9 10.2

Merujuk kepada Lampiran Z2, didapati bahawa sebanyak 82 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran Z3 menunjukkan graf pepadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran Z4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada kelima-lima hari dengan merujuk nilai hasil ramalan hujan pada Jadual 6.14(iv) di atas.

### 6.3.15 Stesen Ldg. Segamat Daerah Segamat

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.15(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.15(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.15(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.01, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.15(i) :** Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Segamat Daerah Segamat.

<b>Fungsi Pembelajaran :<i>TRAINGD</i></b>			
<b>Nod Tersembunyi = 7</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	895	0.009998	0.029555
<b>0.5</b>	80	0.009959	0.033028
<b>0.9</b>	109	0.009931	0.035458
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1170	0.009994	0.034607
<b>0.5</b>	274	0.009988	0.041904
<b>0.9</b>	171	0.009985	0.036118
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1359	0.009995	0.030373
<b>0.5</b>	362	0.009998	0.034740
<b>0.9</b>	154	0.009996	0.034841

**Jadual 6.15 (ii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdm* bagi Stesen Ldg. Segamat Daerah Segamat

<b>Fungsi Pembelajaran :<i>TRAINGDM</i></b>			
<b>Nod Tersembunyi = 7</b>			

Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	642	0.009992	0.029294
	0.5	946	0.009998	0.031899
	0.9	<b>801</b>	<b>0.009997</b>	<b>0.020594</b>
0.5	0.1	171	0.009988	0.026436
	0.5	177	0.009999	0.030594
	0.9	192	0.009983	0.024125
0.9	0.1	95	0.009984	0.031405
	0.5	100	0.009993	0.027381
	0.9	69	0.009577	0.039260
<b>Nod Tersembunyi = 14</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	1015	0.009999	0.046718
	0.5	1277	0.009999	0.035029
	0.9	1387	0.009998	0.041722
0.5	0.1	238	0.009988	0.053094
	0.5	279	0.009999	0.036819
	0.9	276	0.009984	0.039190
0.9	0.1	159	0.009987	0.045817
	0.5	168	0.009992	0.035746
	0.9	73	0.008821	0.039999
<b>Nod Tersembunyi = 15</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE(Latihan)	MSE(Validasi)
0.1	0.1	1815	0.010000	0.051016
	0.5	1505	0.009999	0.038616
	0.9	1906	0.009998	0.036078
0.5	0.1	255	0.009977	0.037484
	0.5	254	0.009986	0.025806
	0.9	189	0.009995	0.033022
0.9	0.1	196	0.009989	0.035183
	0.5	156	0.009983	0.037240
	0.9	127	0.009963	0.057144

**Jadual 6.15(iii) :** Model rangkaian menggunakan fungsi pembelajaran *Traingdx* bagi Stesen Ldg. Segamat Daerah Segamat

<b>Fungsi Pembelajaran : TRAINGDX</b>				
<b>Nod Tersembunyi = 7</b>				
Alfa (lr)	Beta (mc)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	0.1	78	0.009745	0.025451
	0.5	77	0.009993	0.025882
	0.9	90	0.009824	0.026927
0.5	0.1	60	0.009986	0.024998
	0.5	54	0.009921	0.029397
	0.9	67	0.009936	0.027275



<b>0.9</b>	<b>0.1</b>	67	0.009898	0.027696
	<b>0.5</b>	47	0.009927	0.027593
	<b>0.9</b>	69	0.009971	0.025384
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	246	0.009899	0.030082
	<b>0.5</b>	81	0.009833	0.028613
	<b>0.9</b>	100	0.009762	0.030074
<b>0.5</b>	<b>0.1</b>	259	0.009970	0.030440
	<b>0.5</b>	96	0.009920	0.040056
	<b>0.9</b>	68	0.009887	0.031246
<b>0.9</b>	<b>0.1</b>	212	0.009988	0.040088
	<b>0.5</b>	100	0.009974	0.036465
	<b>0.9</b>	91	0.009897	0.033579
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	157	0.009979	0.034483
	<b>0.5</b>	105	0.009951	0.029804
	<b>0.9</b>	105	0.009886	0.033688
<b>0.5</b>	<b>0.1</b>	156	0.009978	0.036622
	<b>0.5</b>	93	0.009965	0.060708
	<b>0.9</b>	79	0.009808	0.051145
<b>0.9</b>	<b>0.1</b>	135	0.009990	0.053298
	<b>0.5</b>	112	0.009971	0.055425
	<b>0.9</b>	78	0.009810	0.040669

Berpandukan kepada Jadual 6.15(i), Jadual 6.15(ii) dan Jadual 6.15(iii), didapati ralat validasi terkecil bagi Stesen Ldg. Segamat Daerah Segamat ialah 0.020594. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.15(ii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran AA1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.15(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.9. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdm* sebagai fungsi pembelajaran.

**Jadual 6.15(iv) :** Model rangkaian yang terbaik bagi Stesen Ldg. Segamat  
Daerah Segamat

<b>Fungsi Pembelajaran: <i>TRAIINGDM</i></b>
<b>Nod Tersembunyi : 7</b>

Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
0.1	0.9	801	0.020594	9.5 0.0 18.7 6.1 7.7

Merujuk kepada Lampiran AA2, didapati bahawa sebanyak 801 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran AA3 menunjukkan graf pemadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran AA4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada hari pertama, ketiga, keempat dan kelima, manakala hari kedua tidak hujan dengan merujuk nilai hasil ramalan hujan pada Jadual 6.15(iv) di atas.

### 6.3.16 Stesen Ldg. Mados Sermin Daerah Segamat

Dengan terlaksananya kod arahan yang telah diterangkan dalam Bab 5, rangkaian akan menjana suatu larian yang mempamerkan 300 kali larian setiap kali paparan. Semasa larian berlaku, fungsi pembelajaran, bilangan larian semasa dan ukuran ralat pembelajaran akan terpapar. Jadual 6.16(i) di bawah menunjukkan model rangkaian yang menggunakan fungsi pembelajaran *traingd*. Manakala Jadual 6.16(ii) menunjukkan model rangkaian dengan menggunakan fungsi *traingdm*. Bagi Jadual 6.16(iii) pula menunjukkan model rangkaian yang menggunakan *traingdx* sebagai fungsi pembelajaran. Ketiga-tiga jadual ini menggunakan nilai sasaran (*goal*) 0.02, nilai *epoch* 10000, dan nilai *show* 300.

**Jadual 6.16(i)** : Model rangkaian menggunakan fungsi pembelajaran *Traingd* bagi Stesen Ldg. Mados Sermin Daerah Segamat

Fungsi Pembelajaran : <i>TRAIINGD</i>			
Nod Tersembunyi = 7			
Alfa (lr)	Lelaran	MSE (Latihan)	MSE (Validasi)
0.1	1388	0.019997	0.020554

<b>0.5</b>	195	0.019988	0.020206
<b>0.9</b>	185	0.019999	0.021000
<b>Nod Tersembunyi = 14</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1962	0.019999	0.020491
<b>0.5</b>	524	0.020000	0.021000
<b>0.9</b>	293	0.019989	0.021060
<b>Nod Tersembunyi = 15</b>			
<b>Alfa (lr)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	1622	0.019998	0.021332
<b>0.5</b>	543	0.019999	0.021248
<b>0.9</b>	181	0.019987	0.021578

**Jadual 6.16(ii) :** Model rangkaian menggunakan fungsi pembelajaran *Trainngdm* bagi Stesen Ldg. Mados Sermin Daerah Segamat

<b>Fungsi Pembelajaran : TRAINGDM</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	935	0.019997	0.021390
	<b>0.5</b>	1567	0.019998	0.020717
	<b>0.9</b>	1384	0.020000	0.021030
<b>0.5</b>	<b>0.1</b>	281	0.019997	0.020804
	<b>0.5</b>	231	0.019989	0.021329
	<b>0.9</b>	222	0.019982	0.021104
<b>0.9</b>	<b>0.1</b>	151	0.019978	0.021306
	<b>0.5</b>	136	0.019999	0.021039
	<b>0.9</b>	130	0.019976	0.021894
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	1355	0.019997	0.022394
	<b>0.5</b>	1703	0.019998	0.021120
	<b>0.9</b>	1277	0.020000	0.021824
<b>0.5</b>	<b>0.1</b>	415	0.019995	0.022377
	<b>0.5</b>	440	0.019999	0.021340
	<b>0.9</b>	373	0.019995	0.021554
<b>0.9</b>	<b>0.1</b>	229	0.019998	0.023206
	<b>0.5</b>	268	0.019990	0.020942
	<b>0.9</b>	198	0.019990	0.021336
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE(Latihan)</b>	<b>MSE(Validasi)</b>
<b>0.1</b>	<b>0.1</b>	2695	0.020000	0.020631
	<b>0.5</b>	2855	0.019999	0.020669
	<b>0.9</b>	2655	0.020000	0.021372

<b>0.5</b>	<b>0.1</b>	306	0.019988	0.021314
	<b>0.5</b>	442	0.019993	0.020423
	<b>0.9</b>	286	0.019996	0.021548
<b>0.9</b>	<b>0.1</b>	283	0.019992	0.021110
	<b>0.5</b>	287	0.020000	0.021859
	<b>0.9</b>	162	0.019974	0.021774

**Jadual 6.16(iii)** : Model rangkaian menggunakan fungsi pembelajaran *Trainidx* bagi Stesen Ldg. Mados Sermin Daerah Segamat

<b>Fungsi Pembelajaran : TRAINIDX</b>				
<b>Nod Tersembunyi = 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	86	0.019860	0.021590
	<b>0.5</b>	<b>86</b>	<b>0.019996</b>	<b>0.019832</b>
	<b>0.9</b>	97	0.019996	0.021139
<b>0.5</b>	<b>0.1</b>	90	0.019963	0.020736
	<b>0.5</b>	60	0.019933	0.020627
	<b>0.9</b>	69	0.019946	0.021750
<b>0.9</b>	<b>0.1</b>	101	0.019973	0.020615
	<b>0.5</b>	56	0.019880	0.020786
	<b>0.9</b>	74	0.019851	0.021188
<b>Nod Tersembunyi = 14</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	377	0.019981	0.020479
	<b>0.5</b>	109	0.019952	0.021848
	<b>0.9</b>	107	0.019858	0.021342
<b>0.5</b>	<b>0.1</b>	378	0.019787	0.021354
	<b>0.5</b>	130	0.019990	0.021078
	<b>0.9</b>	76	0.019833	0.019895
<b>0.9</b>	<b>0.1</b>	308	0.019990	0.021140
	<b>0.5</b>	140	0.019976	0.020080
	<b>0.9</b>	110	0.019819	0.021810
<b>Nod Tersembunyi = 15</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Latihan)</b>	<b>MSE (Validasi)</b>
<b>0.1</b>	<b>0.1</b>	272	0.019987	0.020352
	<b>0.5</b>	169	0.019976	0.021366
	<b>0.9</b>	114	0.019838	0.021447
	<b>0.1</b>	403	0.019999	0.021973

0.5	0.5	148	0.019942	0.021473
	0.9	85	0.019939	0.021523
0.9	0.1	318	0.019800	0.022221
	0.5	149	0.019998	0.021669
	0.9	87	0.019862	0.021256

Berpandukan kepada Jadual 6.16(i), Jadual 6.16(ii) dan Jadual 6.16(iii), didapati ralat validasi terkecil bagi Stesen Ladang Mados Sermin Daerah Segamat ialah 0.019832. Nilai ralat validasi terkecil ini dapat dilihat pada Jadual 6.16(iii). Larian latihan model rangkaian pula boleh dirujuk pada Lampiran AB1. Ini menunjukkan bahawa model ini adalah model yang terbaik daripada model-model lain yang dibangunkan bagi stesen ini. Jadual 6.16(iv) di bawah menunjukkan model rangkaian terbaik dengan nilai kadar pembelajaran dan momentum ialah 0.1 dan 0.5. Manakala nilai 7 adalah nilai bagi nod tersembunyi dan *traingdx* sebagai fungsi pembelajaran.

**Jadual 6.16(iv) :** Model rangkaian yang terbaik bagi Stesen Ladang Mados Sermin Daerah Segamat

<b>Fungsi Pembelajaran: <i>TRAINGDx</i></b>				
<b>Nod Tersembunyi : 7</b>				
<b>Alfa (lr)</b>	<b>Beta (mc)</b>	<b>Lelaran</b>	<b>MSE (Validasi)</b>	<b>Hasil Ramalan Hujan (mm)</b>
0.1	0.5	86	0.019832	5.4 4.3 5.2 2.5 4.1

Merujuk kepada Lampiran AB2, didapati bahawa sebanyak 86 larian untuk model rangkaian mencapai sasaran dengan MSE validasi terkecil. Lampiran AB3 menunjukkan graf pemadanan antara nilai sebenar dengan nilai simulasi bagi data validasi. Lampiran AB4 pula adalah graf taburan hujan bandingan antara data sebenar dengan data ramalan.

Didapati ramalan bagi 5 hari akan datang menunjukkan bahawa berlaku hujan pada kelima-lima hari dengan merujuk nilai hasil ramalan hujan pada Jadual 6.16(iv) di atas.

#### **6.4 Analisa Model Rangkaian Menggunakan Teknik Rangkaian Neural**

Peringkat terakhir setelah memilih model peramalan yang terbaik di dalam projek ini ialah membuat analisa terhadap teknik peramalan rangkaian neural yang digunakan. Analisa adalah tertumpu kepada mengenalpasti sama ada teknik yang digunakan ini boleh menghasilkan model taburan hujan yang terbaik atau sebagainya. Jadual 6.17 menunjukkan ringkasan model terbaik bagi setiap stesen. Penerangan analisa teknik peramalan dengan menggunakan kaedah rangkaian neural bagi setiap stesen adalah merujuk kepada Jadual 6.17.

Hasil output peramalan taburan hujan bagi stesen pertama iaitu Stesen Pasang Surut Kg. Sg. Rengit daerah Batu Pahat dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran M3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran M4.

Bagi stesen kedua iaitu Stesen Ldg. Union Yong Peng daerah Batu Pahat, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah agak memuaskan kerana taburan data hujan bagi validasi menunjukkan sebahagian data yang diramal mengikut aliran data sebenar. Rujuk Lampiran N3. Manakala bandingan antara data hujan sebenar dengan data ramalan sebahagiannya adalah sama. Rujuk Lampiran N4.

Bagi stesen ketiga iaitu Stesen Ldg. Senai daerah Johor Bahru, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data sebenar. Rujuk Lampiran O3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran O4.

Bagi Stesen Ldg. Sg. Tiram daerah Johor Bahru iaitu stesen keempat, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data sebenar. Rujuk Lampiran P3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran P4.

Hasil output peramalan taburan hujan bagi stesen kelima iaitu Stesen Ldg. Simpang Renggam daerah Kluang dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran Q3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran Q4.

Hasil output peramalan taburan hujan bagi stesen keenam iaitu Stesen Ldg. Ulu Paloh daerah Kluang dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data sebenar. Rujuk Lampiran R3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran R4.

Hasil output peramalan taburan hujan bagi stesen ketujuh iaitu Stesen Ldg. Getah Malaya daerah Kota Tinggi dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data

sebenar. Rujuk Lampiran S3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran S4.

Bagi stesen kelapan iaitu Stesen Rancangan Ulu Sebol daerah Kota Tinggi, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data sebenar. Rujuk Lampiran T3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran T4.

Hasil output peramalan taburan hujan bagi stesen kesembilan iaitu Stesen Ibu Bekalan Kahang daerah Mersing dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah agak memuaskan kerana taburan data hujan bagi validasi menunjukkan sebahagian data yang diramal mengikut aliran data sebenar. Rujuk Lampiran U3. Manakala bandingan antara data hujan sebenar dengan data ramalan sebahagiannya adalah sama. Rujuk Lampiran U4.

Hasil output peramalan taburan hujan bagi stesen kesepuluh iaitu Stesen Pusat Pertanian Endau daerah Mersing dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran V3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran V4.

Hasil output peramalan taburan hujan bagi stesen kesebelas iaitu Stesen Ldg. Temiang Renchong daerah Muar dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran W3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran W4.

Bagi stesen kedua belas iaitu Stesen Ldg. Gomali Batu Enam daerah Muar, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah agak memuaskan kerana taburan data hujan



bagi validasi menunjukkan sebahagian data yang diramal mengikut aliran data sebenar. Rujuk Lampiran X3. Manakala bandingan antara data hujan sebenar dengan data ramalan sebahagiannya adalah sama. Rujuk Lampiran X4.

Bagi stesen ketiga belas iaitu Stesen Ldg. Getah Kukup daerah Pontian, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran Y3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran Y4.

Hasil output peramalan taburan hujan bagi stesen keempat belas iaitu Stesen Pintu Pasang Surut Senggarang daerah Pontian dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah kurang memuaskan kerana taburan data hujan bagi validasi menunjukkan tidak banyak data yang diramal mengikut aliran data sebenar. Rujuk Lampiran Z3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya tidak sama. Rujuk Lampiran Z4.

Bagi stesen kelima belas iaitu Stesen Ldg. Segamat daerah Segamat, hasil output peramalan taburan hujan dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah agak memuaskan kerana taburan data hujan bagi validasi menunjukkan sebahagian data yang diramal mengikut aliran data sebenar. Rujuk Lampiran AA3. Manakala bandingan antara data hujan sebenar dengan data ramalan sebahagiannya adalah sama. Rujuk Lampiran AA4.

Hasil output peramalan taburan hujan bagi stesen keenam belas iaitu Stesen Ladang Mados Sermin daerah Segamat dengan menggunakan teknik rangkaian neural ini menunjukkan bahawa prestasi adalah memuaskan kerana taburan data hujan bagi validasi menunjukkan hampir kebanyakan data yang diramal mengikut aliran data sebenar. Rujuk Lampiran AB3. Manakala bandingan antara data hujan sebenar dengan data ramalan kebanyakannya adalah hampir sama. Rujuk Lampiran AB4.

Walaupun terdapat model peramalan taburan hujan daripada beberapa stesen taburan hujan yang menggunakan teknik rangkaian neural ini kurang memuaskan, ini tidak bermakna teknik rangkaian neural tidak sesuai digunakan untuk merekabentuk atau membangunkan model peramalan taburan hujan. Untuk membangunkan model peramalan taburan hujan, ia dipengaruhi oleh beberapa faktor yang mempengaruhi prestasi rangkaianannya. Antara faktor tersebut ialah penggunaan pemalar kadar pembelajaran ( $\eta$ ), pemalar momentum ( $\alpha$ ), kesan penjelmaan data, struktur rangkaian dan bentuk data yang diperolehi. Sebahagian faktor yang mempengaruhi prestasi rangkaian telah diterangkan di dalam Bab 3. Manakala di dalam Bab 7 juga akan diterangkan kesimpulan mengenai faktor yang mempengaruhi prestasi rangkaian.

Jadual 7.17 : Ringkasan model terbaik bagi setiap stesen

Stesen	Fungsi Pembelajaran	Nod Tersembunyi	Alfa (lr)	Beta (mc)	Lelaran	MSE (Validasi)	Hasil Ramalan Hujan (mm)
1	<i>Traingdm</i>	14	0.9	0.9	92	0.008263	6.0 6.5 6.1 7.1 5.9
2	<i>Traingdm</i>	7	0.9	0.5	168	0.021370	4.7 0.0 2.3 4.5 5.4
3	<i>Traingdx</i>	7	0.5	0.1	65	0.014798	4.9 0.0 3.9 19.1 0.0
4	<i>Traingdm</i>	7	0.1	0.9	754	0.019315	56.8 14.4 13.8 0.0 15.0
5	<i>Traingdm</i>	7	0.5	0.1	150	0.018316	3.6 3.3 5.2 3.8 2.2
6	<i>Traingdm</i>	7	0.1	0.5	609	0.010042	2.6 15.2 0.0 11.7 5.0
7	<i>Traingdm</i>	7	0.1	0.9	724	0.013507	11.3 0.0 26.8 2.9 13.9
8	<i>Traingd</i>	7	0.5	-	122	0.007447	9.6 15.0 0.0 8.4 11.5
9	<i>Traingdx</i>	14	0.1	0.9	110	0.013242	9.1 5.8 9.2 3.7 0.0
10	<i>Traingdm</i>	7	0.9	0.5	263	0.011371	10.1 15.3 8.9 11.9 16.9
11	<i>Traingdx</i>	7	0.1	0.5	88	0.036014	7.4 11.8 15.3 0.0 2.5
12	<i>Traingd</i>	7	0.5	-	116	0.010529	5.3 9.3 0.0 9.3 16.1
13	<i>Traingdm</i>	15	0.9	0.9	254	0.009054	5.8 6.1 24.6 14.6 0.0
14	<i>Traingdm</i>	15	0.9	0.9	82	0.009309	3.5 10.0 11.7 1.9 10.2
15	<i>Traingdm</i>	7	0.1	0.9	801	0.020594	9.5 0.0 18.7 6.1 7.7
16	<i>Traingdx</i>	7	0.1	0.5	86	0.019832	5.4 4.3 5.2 2.5 4.1

## **BAB 7**

### **KESIMPULAN**

#### **7.1 Pengenalan**

Peramalan merupakan suatu proses membuat penelahan atau ramalan suatu peristiwa yang akan datang. Peramalan juga merupakan suatu input kepada proses perancangan untuk suatu peristiwa yang tidak tahu apa natijahnya yang akan berlaku. Kebiasaannya individu atau organisasi tertentu yang memilih untuk membuat peramalan adalah bertujuan untuk membuat perancangan awal mengenai sesuatu perkara atau peristiwa pada masa akan datang. Ia bertujuan untuk peningkatan produktiviti yang cemerlang, gemilang dan terbilang bagi sesebuah organisasi atau individu itu sendiri. Dengan adanya peramalan, objektif sesebuah organisasi dapat dicapai sekaligus sasaran pencapaian masa depan organisasi dapat dipenuhi.

Begitu juga dengan terhasilnya kajian ini. Kajian ini telah menghasilkan model peramalan taburan hujan bagi negeri Johor. Dengan terhasilnya model peramalan ini, dapat membantu pihak tertentu terutamanya pihak Jabatan Pengairan dan Saliran Johor (JPS) membuat peramalan taburan hujan untuk masa akan datang. Selain itu pihak JPS juga boleh menggunakan hasil peramalan hujan ini sebagai panduan untuk merancang sesuatu perkara yang berkaitan dengan cuaca. Disamping itu pihak JPS dapat membantu penduduk di setiap daerah yang terlibat dengan

membuat pemberitahuan mengenai ramalan hujan untuk beberapa hari akan datang. Dengan adanya peramalan hujan ini, manusia dapat membuat perancangan awal mengenai aktiviti seharian dan sebagainya.

Teknik yang digunakan dalam membuat model peramalan taburan hujan ini ialah Box-Jenkins dan rangkaian neural. Berdasarkan kepada analisa yang dijalankan, model ramalan Rangkaian Neural telah di pilih sebagai model ramalan terbaik bagi kajian ini. Alasan mengapa model daripada kaedah Box Jenkins tidak di terima akan diterangkan pada bahagian 7.2.

## **7.2 Masalah Dan Cadangan**

Hasil output peramalan hujan yang diperolehi dengan menggunakan kaedah *Box-Jenkins* tidak begitu memuaskan kerana data telah dikelompokkan (*clustering*) dahulu, iaitu mendapatkan purata data untuk setiap stesen mengikut daerah kemudian data tersebut akan menjalani proses *clustering* dengan cara mendapatkan min bagi hasil tambah jumlah hujan harian untuk tarikh yang sama bagi ketiga-tiga tahun tersebut. Kemudian mendapatkan nilai purata untuk 5 hari berturut bagi daerah yang sama. Ini menunjukkan data telah dikurangkan. Maka, kita tidak dapat meramalkan hari esok atau hari akan datang samada hujan atau tidak. Berdasarkan kepada kajian yang dilakukan di dapati kaedah *Box-Jenkins* tidak sesuai digunakan terhadap jukat data yang terlampau besar. Selain itu, beberapa hasil output peramalan hujan yang di buat melalui kaedah Box Jenkins mengandungi nilai ramalan yang kurang dari 0. Ini adalah tidak munasabah kerana data hujan tidak boleh kurang daripada 0 mm. Justeru, kaedah peramalan menggunakan rangkaian neural di aplikasikan di dalam kajian ini.

Peramalan taburan hujan yang dibangunkan ini mengandungi bilangan data yang banyak, iaitu sebanyak 15 088 nilai bacaan. Maka kaedah sesuai yang

dicadangkan untuk membangunkan model peramalan yang baik ialah kaedah rangkaian neural (*Neural Network*) dengan menggunakan pendekatan rambatan ke belakang (*Back Propagation*) sebagai algoritma.

Kaedah rangkaian neural ini merupakan perisian komputer yang meniru kemampuan otak manusia berfikir untuk mengecam dan membuat keputusan. Dengan menggunakan kaedah ini, tiada had dalam menetapkan bilangan input. Maka dengan kaedah ini, diandaikan dapat menghasilkan model peramalan hujan yang baik.

Dengan menggunakan kaedah ini, set data perlu dibahagikan kepada set data pembelajaran, set data pengujian dan akhir sekali set data pengesahan. Penentuan bagi set data pembelajaran adalah untuk melatih dan membangunkan model rangkaian neural. Bagi pengujian pula digunakan untuk menguji keupayaan rangkaian untuk melakukan penggiatan. Dengan mencadangkan penggunaan kaedah rangkaian neural dalam membangunkan model peramalan hujan, maka data hujan yang diperolehi tidak perlu dikelompokkan (*cluster*). Ini bermaksud data tidak akan dikurangkan dengan tidak perlu untuk mendapatkan purata. Ini kerana penggunaan kaedah rangkaian neural tiada had dalam menetapkan bilangan input. Selain itu, penggunaan kaedah rangkaian neural ini memerlukan penjelmaan data kerana pendekatan algoritma *Back Propagation* hanya boleh membaca nilai input antara -1 hingga 1 sahaja. Oleh itu, kesemua data akan dijelmakan dahulu sebelum data disusun dan seterusnya boleh melakukan proses pembelajaran. Apabila hasil output telah diperolehi, data-data yang terhasil akan dijelmakan semula untuk mendapatkan nilai data hujan yang pada asalnya dalam unit milimeter.

Walaupun kaedah rangkaian neural ini dipilih untuk membangunkan model peramalan berdasarkan kepada beberapa sebab yang dinyatakan, namun untuk membangunkan model peramalan taburan hujan ini, masih juga terdapat beberapa masalah.

Masalah yang sering dihadapi semasa membangunkan model peramalan hujan ini adalah julat antara data. Julat data hujan yang diperolehi adalah besar, sebagai contoh beza kuantiti sukatan hujan di antara dua hari agak besar dan jauh berbeza. Terdapat juga tiada hujan berlaku pada sesuatu hari itu, tetapi keesokan harinya berlaku hujan yang agak lebat.

Disebabkan dengan julat data hujan yang besar, adalah agak sukar untuk melakukan proses pembelajaran data samada tempoh masa penumpuan untuk mencapai sasaran agak lama atau tiada penumpuan berlaku. Dengan itu, nilai sasaran (*goal*) model rangkaian perlu diubah.

Di awal perancangan untuk membangunkan model ini, nilai sasaran telah dicadangkan agar diselaraskan untuk semua stesen. Walaupun tiada kaitan di antara satu stesen dengan stesen yang lain. Nilai sasaran yang dicadangkan ialah 0.01. Tujuan untuk menyelaraskan nilai sasaran adalah untuk memudahkan membuat analisa, dan untuk memastikan sama ada setiap stesen dapat mencapai sasaran larian semasa proses pembelajaran. Nilai sasaran yang diubah ialah 0.015, 0.02 dan 0.03. Nilai ini dipilih kerana model tidak dapat menumpu apabila nilai sasaran ditetapkan dengan 0.01. Manakala apabila nilai sasaran diubah kepada 0.1 pula, larian latihan terlalu cepat menumpu dengan bilangan larian latihan yang agak kecil, hasil daripada proses pengesahan model pula tidak begitu memuaskan. Oleh itu, nilai sasaran perlu diubah. Walau bagaimanapun, nilai sasaran masih lagi kecil dan ianya kurang daripada satu.

Sebagai cadangan kepada masalah ini, ialah pengujian model perlu dibuat dengan lebih banyak lagi dengan menggunakan nilai sasaran yang berbeza-beza. Dengan menggunakan pendekatan cuba jaya, masa yang lama diperlukan untuk melakukan proses pengujian iaitu dengan menggunakan kombinasi pelbagai nilai sasaran, parameter kadar pembelajaran, momentum, struktur rangkaian, aras tersembunyi dan fungsi penggiatan. Ini bertujuan untuk mendapatkan model yang lebih baik dan boleh dipercayai dengan aliran (*trend*) data validasi mengikut atau mempunyai hampir sama dengan data sebenar dan terutama sekali nilai ramalan adalah kebanyakannya sama dengan nilai data sebenar. Setiap stesen yang

digunakan di dalam projek ini mempunyai satu model rangkaian yang terbaik walaupun bilangan model yang dibangunkan untuk sesuatu stesen adalah terhad .

### 7.3 Kesimpulan

Setelah analisa hasil dibuat, dapat disimpulkan bahawa terdapat beberapa faktor yang mempengaruhi rangkaian. Antaranya ialah penggabungan nilai kadar pembelajaran dengan momentum. Di dapati secara keseluruhannya hampir kesemua model iaitu termasuk juga model yang terbaik, dengan bertambahnya nilai kadar pembelajaran, bilangan larian semakin berkurangan. Ini menunjukkan semakin besar nilai kadar pembelajaran, pencapaian larian latihan semakin cepat menumpu. Walau bagaimanapun, nilai kadar pembelajaran dan momentum bagi setiap larian masih lagi diselaraskan dengan nilai 0.1, 0.5 dan 0.9.

Merujuk kepada prestasi setiap larian apabila nilai nod tersembunyi diubah antara 7, 14 atau 15 atau mengubah fungsi pembelajaran samada fungsi *traingd*, fungsi *traingdm* atau fungsi *traingdx*. Diperhatikan, apabila berubahnya nod tersembunyi dari nilai 7 ke nilai 14 dan kemudian ke nilai 15, didapati nilai ralat validasi semakin tinggi. Merujuk kepada jadual-jadual model rangkaian bagi setiap stesen yang terdapat dalam Bab 6, hampir kesemua model terbaik adalah terhasil daripada model rangkaian yang menggunakan unit 7 sebagai nod tersembunyi. Ini menunjukkan bahawa semakin bertambahnya nilai nod bagi aras tersembunyi, ralat validasi terkecil tidak dapat dicapai. Secara umumnya hasil yang diperolehi menunjukkan bahawa kebanyakan ralat yang terhasil daripada model yang dibangunkan semakin berkurang apabila nilai kadar pembelajaran berubah dari 0.1 kepada 0.9. Begitu juga perubahan nilai pemalar momentum.

Selain itu, jika diperhatikan dengan mengubah fungsi pembelajaran daripada *traingd* ke *traingdm*, dan dari *traingdm* ke *traingdx* menunjukkan bahawa nilai ralat validasi terkecil dapat dicapai apabila fungsi pembelajaran *traingdm* digunakan. Ini



menunjukkan bahawa momentum mempengaruhi nilai pemberat dan bias berdasarkan kecerunan rangkaian apabila pemberat dan bias dikemaskini.

Kesimpulan yang boleh dibuat ialah teknik peramalan rangkaian neural adalah sesuai digunakan untuk membuat model peramalan taburan hujan. Ini kerana, setiap stesen mempunyai model yang terbaik. Dengan erti kata lain, ralat validasi dapat dicapai walaupun penggunaan nilai kadar pembelajaran dan momentum adalah terhad. Selain itu, kaedah rangkaian neural ini amat sesuai digunakan untuk meramal taburan hujan kerana bagi bilangan data input dan data output tiada had yang tertentu. Begitu juga bilangan aras tersembunyi. Rangkaian neural tidak membataskan atau menghadkan bilangan aras tersembunyi, bilangan nod input dan bilangan nod output. Dengan bilangan data yang banyak akan dapat menghasilkan ramalan yang lebih baik. Walau bagaimanapun, tiada fakta mengatakan dengan menambah bilangan aras tersembunyi akan menghasilkan model terbaik, sebaliknya model terbaik dapat dibangunkan dengan melihat kepada faktor-faktor yang mempengaruhi model rangkaian seperti pemalar kadar pembelajaran dan pemalar momentum.

Dengan terhasilnya model-model peramalan hujan ini, dan analisa yang telah dibuat, didapati model ini juga boleh diaplikasikan kepada peristiswa atau keadaan lain yang memerlukan perancangan untuk masa hadapan. Diharap dengan terhasilnya projek ini, model ini dapat diaplikasikan untuk peristiwa atau perancangan pihak-pihak tertentu yang memerlukan ramalan perancangan masa hadapan untuk meningkatkan prestasi dan produktiviti.

## RUJUKAN

- [1] Perkhidmatan Kaji Cuaca Malaysia:  
<http://www.kjc.gov.my/malay/perkhidmatan/iklim/oci.html>
  
- [2] Jabatan Pengairan dan Saliran Johor:  
<http://www.jpsjohor.gov.my/jps-mekanikal/http://www.jpsjohor.gov.my/jps-JohorBahru>
  
- [3] L. Bruce, T. I. Richard., 1987. Penelahan Siri Masa, Terbitan Dewan Bahasa dan Pustaka, Kementerian Pendidikan Malaysia
  
- [4] Bruce L. Bowerman, Richard T O'Connell (1987) Time Series Forecasting: Unified Concepts And Computing Implementation 2nd Edition: Duxbury Press
  
- [5] Fauset, L. (1994). *Fundamentals Of Neural Networks Architectures, Algorithms, And Applications* New Jersey: Prentice Hall.
  
- [6] Wong, F. S. (1991), *Time Series Forecasting Using Backpropagation Neural Network*.
  
- [7] Najmi Wahidi Abu Bakar (2002). *Kesan Penormalan Data dan Struktur Rangkaian Neural Terhadap Prestasi Rangkaian Neural Dalam Peramalan Kajian Kes Kemasukkan Pelawat Ke Langkawi*. Universiti Teknologi Malaysia: Tesis Sarjana Muda.
  
- [8] Syed Taha Syed Zaid (2000). *Peramalan Harga Kopi Untuk Pasaran Komoditi Dunia Untuk Pasaran Masa Depan*. Universiti Teknologi Malaysia: Tesis Sarjana Muda.
  
- [9] Sharda, R. (1994). *Neural Network for the MS/or Analyst: An Application Bibliography Interfaces*.

- [10] Bishop, C. M. (1996). *Neural Networks :A Patten Recognition Perspective*. Neural Computing Research Group Aston University: Birmingham. UK.
- [11] Demuth. H. and Beale. M. (2000). *Neural Network Toolbox For Use with Matlab*. Natick: The Math Works, Inc.
- [12] Kang, S. (1991). *An Investigation of The Use of Feedforward Neural Network For Forecasting*. Kent State University: PhD Thesis.
- [13] Math Works. (2000). *MATLAB The Language of Technical Computing*. Natick: The Math Works, Inc.
- [14] Tatsuya L., Tetsuro M., Yoshikazu F., and member (2001). *Water Flow Forecasting Using Analyzable Structured Neural Network*. IEE International Conference on Intelligent System Application to Power System. 19-8505.

## LAMPIRAN A

Senarai stesen taburan hujan

	<b>Stesen ID</b>	<b>Stesen Nama</b>	<b>Daerah</b>
1	1631001	Pintu Pasang Surut Kg.Sg.Rengit	Batu Pahat
2	2130068	Ldg. Union Yong Peng	Batu Pahat
3	1536110	Ldg. Senai	Johor Bahru
4	1539134	Ldg. Sg. Tiram	Johor Bahru
5	1833092	Ldg. Simpang Rengam	Kluang
6	2132154	Ldg. Ulu Paloh	Kluang
7	1738131	Ldg. Getah Malaya	Kota Tinggi
8	1836001	Rancangan Ulu Sebol	Kota Tinggi
9	2235163	Ibu Bekalan Kahang	Mersing
10	2636169	Pusat Pertanian Endau	Mersing
11	2127018	Ldg. Temiang Renchong	Muar
12	2626002	Ldg. Gomali Batu Enam	Muar
13	1334108	Ldg. Getah Kukup	Pontian
14	1730082	Pintu Pasang Surut Senggarang	Pontian
15	2428011	Ldg. Segamat	Segamat
16	2628001	Ldg. Mados Sermin	Segamat


## **LAMPIRAN B**

Alat pengukuran hujan

**LAMPIRAN B1**  
Kawasan Pencerapan




**LAMPIRAN B2**  
*Adang Stevenson*



### LAMPIRAN B3

Termometer Kering dan Basah




### LAMPIRAN B4

Termometer Maksima dan Termometer Minima




## LAMPIRAN B5

Termograf



## LAMPIRAN B6

Higrograf





## LAMPIRAN B7

Penyukat Sejatan




## LAMPIRAN B8

Tolok Cangkuk




## LAMPIRAN B9

*Cups Anemometer*



## LAMPIRAN B10

Tolok Hujan



## LAMPIRAN B11

### Perakam Hujan



## LAMPIRAN B12

Perakam Penyinaran Matahari





## LAMPIRAN B13

*Thedolite (Tracking Balloon)*



## LAMPIRAN B14

Anemometer



## **LAMPIRAN C**

Contoh sebahagian data taburan hujan yang diterima.

Stesen : Pintu Pasang Surut Kampung Sungai Rengit Daerah Batu Pahat

## LAMPIRAN C

Contoh sebahagian data taburan hujan yang diterima.

Stesen : Pintu Pasang Surut Kampung Sungai Rengit Daerah Batu Pahat

**Daily totals    Year 2000    site 1631001 PINTU PASANG SURUT KG. at  
SG. RENGIT, JOHOR**

Rain mm

Day	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
1	0.0	0.0	0.0	10.0	0.0	0.0	0.0	37.5	0.0	27.0	0.0	0.0
2	5.0	0.0	5.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	55.5	0.0	0.0	0.0	0.0
4	0.0	0.0	0.0	0.0	0.0	23.0	0.0	0.0	20.0	0.0	0.0	0.0
5	7.0	0.0	0.0	5.0	0.0	0.0	0.0	35.0	0.0	26.5	0.0	0.0
6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7	10.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
8	0.0	0.0	7.0	0.0	0.0	0.0	10.0	0.0	17.0	0.0	0.0	0.0
9	5.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
10	0.0	0.0	0.0	5.5	0.0	25.0	0.0	0.0	17.5	5.0	0.0	0.0
11	10.0	5.0	0.0	0.0	0.0	0.0	0.0	77.0	0.0	0.0	0.0	0.0
12	0.0	0.0	10.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	14.5
13	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18.0	0.0
14	8.0	10.0	0.0	0.0	0.0	20.5	0.0	0.0	0.0	17.5	10.0	0.0
15	0.0	0.0	0.0	10.5	16.0	0.0	5.0	97.0	0.0	17.0	0.0	45.5
16	0.0	0.0	15.0	0.0	0.0	0.0	0.0	25.0	0.0	0.0	0.0	0.0
17	10.0	0.0	0.0	0.0	14.0	0.0	0.0	0.0	40.0	0.0	0.0	95.5
18	0.0	0.0	0.0	0.0	0.0	25.5	0.0	60.5	38.5	21.5	58.0	0.0
19	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	29.5	7.5	5.0	0.0
20	5.0	5.0	5.0	7.0	0.0	0.0	0.0	0.0	7.5	26.0	28.0	55.0
21	0.0	0.0	0.0	0.0	0.0	0.0	5.5	0.0	0.0	0.0	40.0	0.0
22	0.0	0.0	5.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	16.0	5.0
23	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	16.5	0.0	0.0
24	0.0	15.5	0.0	4.0	0.0	0.0	30.0	0.0	0.0	0.0	0.0	0.0
25	10.0	10.0	0.0	0.0	0.0	0.0	45.0	0.0	17.5	0.0	6.5	0.0
26	0.0	12.0	0.0	0.0	0.0	0.0	95.0	0.0	0.0	0.0	0.0	0.0
27	0.0	0.0	0.0	0.0	0.0	0.0	0.0	62.5	0.0	0.0	0.0	0.0
28	0.0	0.0	10.5	5.0	18.0	30.0	0.0	0.0	0.0	0.0	0.0	0.0
29	0.0	0.0	0.0	0.0	0.0	0.0	60.0	0.0	0.0	0.0	0.0	65.0
30	6.0		5.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	36.0	95.0
31	0.0		0.0		0.0		0.0	34.5		0.0		0.0
Min	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Tot	76.0	57.5	63.5	47.0	48.0	124.0	250.5	484.5	187.5	164.5	217.5	375.5
Max	10.0	15.5	15.0	10.5	18.0	30.0	95.0	97.0	40.0	27.0	58.0	95.5
NO>0.0	10	6	8	7	3	5	7	9	8	9	9	7





Daily totals **Year 2002** site 1631001 PINTU PASANG SURUT KG. at  
**SG. RENGIT, JOHOR**  
Rain mm

Day	Jan	Feb	Mar	Apr	May	Jun	Jul	
1	0.0	0.0	5.0	0.0	11.0	0.0	0.0	
2	0.0	0.0	12.5	0.0	0.0	0.0	40.5	
3	0.0	0.0	42.0	0.0	0.0	0.0	0.0	
4	0.0	0.0	0.0	0.0	23.5	0.0	0.0	
5	0.0	0.0	0.0	10.0	33.0	0.0	0.0	
6	0.0	0.0	0.0	46.0	22.0	0.0	0.0	
7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
8	0.0	0.0	0.0	5.0	58.5	0.0	0.0	
9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
10	0.0	0.0	0.0	0.0	0.0	8.0	18.5	
11	0.0	0.0	0.0	25.0	0.0	0.0	0.0	
12	10.0	0.0	0.0	0.0	0.0	0.0	0.0	
13	0.0	10.0	0.0	0.0	0.0	0.0	20.5	
14	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
15	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
16	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
17	0.0	0.0	10.0	0.0	0.0	0.0	0.0	
18	0.0	0.0	30.0	20.0	0.0	0.0	38.5	
19	20.0	0.0	0.0	0.0	0.0	0.0	0.0	
20	65.0	0.0	0.0	0.0	12.0	15.0	0.0	
21	15.0	0.0	0.0	0.0	0.0	0.0	0.0	
22	10.5	0.0	0.0	34.0	10.0	0.0	0.0	
23	0.0	0.0	0.0	0.0	0.0	20.0	18.0	
24	70.0	0.0	0.0	0.0	10.0	0.0	0.0	
25	0.0	37.5	0.0	0.0	0.0	0.0	0.0	
26	0.0	16.5	5.0	0.0	16.5	0.0	0.0	
27	0.0	0.0	0.0	63.0	0.0	0.0	10.0	
28	0.0	26.0	0.0	0.0	0.0	0.0	0.0	
29	0.0		0.0	0.0	0.0	0.0	13.0	
30	0.0		0.0	10.0	0.0	0.0	0.0	
31	0.0		10.5		0.0		0.0	
Min	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Tot	190.5	90.0	115.0	213.0	196.5	43.0	159.0	1007.0
Max	70.0	37.5	42.0	63.0	58.5	20.0	40.5	70.0
NO>0.0	6	4	7	8	9	3	7	44

## **LAMPIRAN D**

Contoh sebahagian data disusun

## LAMPIRAN D

Contoh Sebahagian Data Disusun

STESEN	BLN	INPUT							OUTPUT				
1	1	14.5	89.5	53.5	56	49.5	28.5	1.5	0.2	0.1	0.1	3.5	0.2
1		89.5	53.5	56	49.5	28.5	1.5	0.2	0.1	0.1	3.5	0.2	11.5
1		53.5	56	49.5	28.5	1.5	0.2	0.1	0.1	3.5	0.2	11.5	2
1		56	49.5	28.5	1.5	0.2	0.1	0.1	3.5	0.2	11.5	2	1
1		49.5	28.5	1.5	0.2	0.1	0.1	3.5	0.2	11.5	2	1	3.5
1		28.5	1.5	0.2	0.1	0.1	3.5	0.2	11.5	2	1	3.5	6.5
1		1.5	0.2	0.1	0.1	3.5	0.2	11.5	2	1	3.5	6.5	42.5
1		0.2	0.1	0.1	3.5	0.2	11.5	2	1	3.5	6.5	42.5	17
1		0.1	0.1	3.5	0.2	11.5	2	1	3.5	6.5	42.5	17	5
1		0.1	3.5	0.2	11.5	2	1	3.5	6.5	42.5	17	5	0.2
1		3.5	0.2	11.5	2	1	3.5	6.5	42.5	17	5	0.2	6.5
1		0.2	11.5	2	1	3.5	6.5	42.5	17	5	0.2	6.5	0
1		11.5	2	1	3.5	6.5	42.5	17	5	0.2	6.5	0	18
1		2	1	3.5	6.5	42.5	17	5	0.2	6.5	0	18	37
1		1	3.5	6.5	42.5	17	5	0.2	6.5	0	18	37	3
1		3.5	6.5	42.5	17	5	0.2	6.5	0	18	37	3	0
1		6.5	42.5	17	5	0.2	6.5	0	18	37	3	0	1.5
1		42.5	17	5	0.2	6.5	0	18	37	3	0	1.5	2
1		17	5	0.2	6.5	0	18	37	3	0	1.5	2	1
1		5	0.2	6.5	0	18	37	3	0	1.5	2	1	0
1	0.2	6.5	0	18	37	3	0	1.5	2	1	0	0	
1	6.5	0	18	37	3	0	1.5	2	1	0	0	1	
1	0	18	37	3	0	1.5	2	1	0	0	1	0	
1	18	37	3	0	1.5	2	1	0	0	1	0	0	
1	2	37	3	0	1.5	2	1	0	0	1	0	0	0
1		3	0	1.5	2	1	0	0	1	0	0	0	0
1		0	1.5	2	1	0	0	1	0	0	0	0	0
1		1.5	2	1	0	0	1	0	0	0	0	0	0
1		2	1	0	0	1	0	0	0	0	0	0	0
1		1	0	0	1	0	0	0	0	0	0	0	0
1		0	0	1	0	0	0	0	0	0	0	0	0
1		0	1	0	0	0	0	0	0	0	0	0	0
1		1	0	0	0	0	0	0	0	0	0	0	0
1		0	0	0	0	0	0	0	0	0	0	0	39.5
1		0	0	0	0	0	0	0	0	0	0	39.5	28
1		0	0	0	0	0	0	0	0	0	39.5	28	0
1		0	0	0	0	0	0	0	0	39.5	28	0	2
1		0	0	0	0	0	0	0	39.5	28	0	2	4.5
1		0	0	0	0	0	0	39.5	28	0	2	4.5	6
1		0	0	0	0	39.5	28	0	2	4.5	6	0	3
1		0	0	39.5	28	0	2	4.5	6	0	3	2.5	0.5
1		0	39.5	28	0	2	4.5	6	0	3	2.5	0.5	3.5
1		39.5	28	0	2	4.5	6	0	3	2.5	0.5	3.5	5
1		28	0	2	4.5	6	0	3	2.5	0.5	3.5	5	8.5
1	0	2	4.5	6	0	3	2.5	0.5	3.5	5	8.5	12.5	
1	2	4.5	6	0	3	2.5	0.5	3.5	5	8.5	12.5	0	
1	4.5	6	0	3	2.5	0.5	3.5	5	8.5	12.5	0	0	
1	6	0	3	2.5	0.5	3.5	5	8.5	12.5	0	0	0	



**LAMPIRAN E: PENENTUAN MODEL PERAMALAN BAGI DAERAH BATU PAHAT**

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(1,0,0) MS Residual=19.434						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf
p(1)	-0.584027	0.105832	-5.51842	0.000001	-0.795103	-0.372951

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=17.147						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf
p(1)	#####	#####	#####	#####	#####	#####
p(2)	#####	#####	#####	#####	#####	#####

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=17.147						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf
p(1)	#####	#####	#####	#####	#####	#####
p(2)	#####	#####	#####	#####	#####	#####

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=15.124						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 68)	p	Lower 95% Conf	Upper 95% Conf
p(1)	#####	#####	#####	#####	-1.13670	#####
p(2)	#####	#####	#####	#####	-0.92252	#####
p(3)	#####	#####	#####	#####	-0.63405	#####

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=12.827						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf
q(1)	0.932017	0.033288	27.99901	0.00	0.865628	0.998407

Input: BP : D(-1); D(-1) (SEMUA) Transformations: none Model:(3,0,3) MS Residual=11.163						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 65)	p	Lower 95% Conf	Upper 95% Conf
p(1)	#####	#####	#####	#####	-0.76581	0.250877
p(2)	0.363007	#####	2.00551	#####	0.00151	0.724499
p(3)	#####	#####	#####	#####	-0.48242	0.089822
q(1)	1.047674	#####	4.54446	#####	0.58726	1.508091
q(2)	0.473641	#####	1.19134	#####	-0.32036	1.267642
q(3)	#####	#####	#####	#####	-1.11375	#####

	Exponential smoothing: S0=.1541 (SEMUA) No trend, no season ; Alpha=0.00 BP : D(-1); D(-1)
Summary of error	Error
Mean error	0.000000000000
Mean absolute error	4.23385577943
Sums of squares	1959.08026696422
Mean square	27.59267981640
Mean percentage error	99.62267495526
Mean abs. perc. error	2.55492493492

	Exponential smoothing: S0=.1276 (SEMUA) No trend, no season ; Alpha=0.00 BP : D(-1); D(-1); ARIMA (1,0,0) residuals;
Summary of error	Error
Mean error	0.000000000000
Mean absolute error	3.48416772405
Sums of squares	1359.21482005373
Mean square	19.14387070498
Mean percentage error	101.02476470495
Mean abs. perc. error	-3.20075417425

	Exponential smoothing: S0=.1747 (SEMUA) No trend, no season ; Alpha=0.00 BP : D(-1); D(-1); ARIMA (2,0,0) residuals;
Summary of error	Error
Mean error	0.000000000000
Mean absolute error	3.28880932245
Sums of squares	1180.95906539720
Mean square	16.63322627320
Mean percentage error	87.35632803701
Mean abs. perc. error	-3.23786975257

	Exponential smoothing: S0=.5969 (SEMUA) No trend, no season ; Alpha=0.00 BP : D(-1); D(-1); ARIMA (0,0,2) residuals;
Summary of error	Error
Mean error	-0.000000000000
Mean absolute error	2.711397062212
Sums of squares	804.807084935770
Mean square	11.335311055433
Mean percentage error	76.352140094898
Mean abs. perc. error	-10.459612099850

**LAMPIRAN F: PENENTUAN MODEL PERAMALAN BAGI DAERAH JOHOR BAHRU**

Input: JB : D(-1) (SEMUA) Transformations: none Model:(1,0,0) MS Residual=13.659								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST
p(1)	-0.165823	0.124360	-1.33341	0.186658	-0.413789	0.082143	fail	10.72217
Input: JB : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=13.728								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	-0.182746	0.126474	-1.44493	0.152940	-0.434990	0.069499	fail	11.42469
p(2)	-0.100930	0.126476	-0.79802	0.427561	-0.353178	0.151319	fail	6.309622
Input: JB : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=13.270								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	-0.224799	0.126459	-1.77765	0.079867	-0.477077	0.027478	fail	14.0571972
p(2)	-0.148178	0.127005	-1.16671	0.247343	-0.401545	0.105189	fail	9.18638359
p(3)	-0.237997	0.129774	-1.83393	0.070976	-0.496889	0.020895	fail	14.1317321
Input: JB : D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=13.530								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
q(1)	0.248982	0.172987	1.439308	0.154458	-0.095945	0.593909	fail	8.3203063
Input: JB : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=12.974								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
q(1)	0.403713	0.132817	3.039619	0.003330	0.138818	0.668608	pass	22.885789
q(2)	0.304922	0.130737	2.332332	0.022565	0.044175	0.565670	pass	17.8398559
Input: JB : D(-1) (SEMUA) Transformations: none Model:(1,0,1) MS Residual=12.444								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	0.551543	0.138339	3.98690	0.000162	0.275635	0.827451	pass	28.8198187
q(1)	0.910190	0.065466	13.90333	0.000000	0.779623	1.040757	pass	212.376239

	Exponential smoothing: S0=.5295 (SEMUA) No trend, no season ; Alpha=.100 JB : D(-1); ARIMA (0,0,2) residuals;
Summary of error	Error
Mean error	0.201243324086
Mean absolute error	2.785621310261
Sums of squares	937.676157707109
Mean square	13.023279968154
Mean percentage error	91.090099341444
Mean abs. perc. error	10.235135588066
	Exponential smoothing: S0=.5295 (SEMUA) No trend, no season ; Alpha=.100 JB : D(-1); ARIMA (0,0,2) residuals;
Summary of error	Error
Mean error	0.201243324086
Mean absolute error	2.785621310261
Sums of squares	937.676157707109
Mean square	13.023279968154
Mean percentage error	91.090099341444
Mean abs. perc. error	10.235135588066



## LAMPIRAN G: PENENTUAN MODEL PERAMALAN BAGI DAERAH KLUANG

Input: KLUANGA : D(-1) (SEMUA) Transformations: none Model:(1,0,0) MS Residual=9.8622								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	-0.257254	0.118399	-2.17277	0.033137	-0.493334	-0.021173	pass	18.3512827

Input: KLUANGA : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=9.4169								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	-0.311270	0.118606	-2.62440	0.010649	-0.547822	-0.074718	pass	22.12
p(2)	-0.250404	0.120822	-2.07250	0.041903	-0.491377	-0.009432	pass	17.15

Input: KLUANGA : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=9.1852								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
p(1)	-0.371509	0.122701	-3.02777	0.003463	-0.616290	-0.126728	pass	24.6760726
p(2)	-0.300187	0.123090	-2.43876	0.017315	-0.545744	-0.054629	pass	19.8128553
p(3)	-0.212695	0.128831	-1.65096	0.103291	-0.469706	0.044316	fail	12.8149258

Input: KLUANGA : D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=8.7200								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
q(1)	0.749046	0.118408	6.325980	0.000000	0.512948	0.985145	pass	53.42528

Input: KLUANGA : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=8.1220								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P probability test	t TEST =abs(v3/v2)
q(1)	0.519803	0.119386	4.353986	0.000045	0.281696	0.757911	pass	36.46992
q(2)	0.289073	0.115948	2.493124	0.015030	0.057822	0.520324	pass	21.50207

	Exponential smoothing: S0=.0379 (SEMUA) No trend, no season ; Alpha=.100 KLUANGA : D(-1); ARIMA (1,0,0) residuals;
	Error
Summary of error	
Mean error	0.086592358984
Mean absolute error	2.599040479152
Sums of squares	764.706083991383
Mean square	10.620917833214
Mean percentage error	105.517369552623
Mean abs. perc. error	19.411015788480
	Exponential smoothing: S0=.0453 (SEMUA) No trend, no season ; Alpha=.100 KLUANGA : D(-1); ARIMA (2,0,0) residuals;
	Error
Summary of error	
Mean error	0.10842455369
Mean absolute error	2.60801774577
Sums of squares	715.19808848199
Mean square	9.93330678447
Mean percentage error	298.20585247565
Mean abs. perc. error	213.99752625843
	Exponential smoothing: S0=-.046 (SEMUA) No trend, no season ; Alpha=.100 KLUANGA : D(-1); ARIMA (0,0,1) residuals;
	Error
Summary of error	
Mean error	0.153430939483
Mean absolute error	2.443652756235
Sums of squares	650.758679896693
Mean square	9.038314998565
Mean percentage error	84.196448636427
Mean abs. perc. error	-6.392190950438
	Exponential smoothing: S0=-.139 (SEMUA) No trend, no season ; Alpha=.100 KLUANGA : D(-1); ARIMA (1,0,1) residuals;
	Error
Summary of error	
Mean error	0.169071370013
Mean absolute error	2.328230097648
Sums of squares	594.702380050554
Mean square	8.259755278480
Mean percentage error	123.282103912251
Mean abs. perc. error	48.723070185780

**LAMPIRAN H : PENENTUAN MODEL PERAMALAN BAGI DAERAH KOTA TINGGI**

Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(1,0,0) MS Residual=13.864								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
p(1)	-0.463188	0.113326	-4.08721	0.000113	-0.689155	-0.237222	pass	36.0658
Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=14.060								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
p(1)	-0.467503	0.123155	-3.79604	0.000310	-0.713129	-0.221877	pass	30.8231
p(2)	-0.012114	0.129876	-0.09327	0.925953	-0.271143	0.246915	fail	0.71816
Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=13.796								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
p(1)	-0.489751	0.122882	-3.98553	0.000165	-0.734894	-0.244608	pass	32.4338
p(2)	-0.070544	0.134295	-0.52529	0.601063	-0.338455	0.197367	fail	3.911496
p(3)	-0.219399	0.144452	-1.51883	0.133373	-0.507574	0.068775	fail	10.51443
Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=14.009								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
q(1)	0.526607	0.131501	4.004584	0.000153	0.264336	0.788877	pass	30.45287
q(2)	0.011450	0.127546	0.089772	0.928725	-0.242932	0.265832	fail	0.703842
Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=14.009								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
q(1)	0.526607	0.131501	4.004584	0.000153	0.264336	0.788877	pass	30.45287
q(2)	0.011450	0.127546	0.089772	0.928725	-0.242932	0.265832	fail	0.703842
Input: KOTA : D(-1) (SEMUA) Transformations: none Model:(3,0,3) MS Residual=13.193								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 66)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2)
p(1)	-0.404066	0.305988	-1.32053	0.191219	-1.01499	0.206859	fail	4.315621
p(2)	-0.278739	0.385696	-0.72269	0.472423	-1.04881	0.491328	fail	1.873731
p(3)	0.245398	0.378225	0.64881	0.518710	-0.50975	1.000549	fail	1.715415
q(1)	0.173581	0.306223	0.56685	0.572742	-0.43781	0.784976	fail	1.851084
q(2)	-0.147279	0.187023	-0.78749	0.433813	-0.52068	0.226124	fail	4.210674
q(3)	0.777712	0.357360	2.17627	0.033119	0.06422	1.491204	pass	6.089855

	Exponential smoothing: S0=.2922 (SEMUA) No trend, no season ; Alpha=.100 KOTA : D(-1); ARIMA (1,0,0) residuals;
	Error
Summary of error	
Mean error	0.19522740858
Mean absolute error	2.74000933705
Sums of squares	1047.22127562237
Mean square	14.54473993920
Mean percentage error	101.90381573175
Mean abs. perc. error	10.07068616903

	Exponential smoothing: S0=.3716 (SEMUA) No trend, no season ; Alpha=.100 KOTA : D(-1); ARIMA (0,0,1) residuals;
	Error
Summary of error	
Mean error	0.25550546008
Mean absolute error	2.67343118556
Sums of squares	1018.85234393819
Mean square	14.15072699914
Mean percentage error	71.08784659078
Mean abs. perc. error	-30.57719539558

	Exponential smoothing: S0=.4134 (SEMUA) No trend, no season ; Alpha=.100 KOTA : D(-1); ARIMA (2,0,1) residuals;
	Error
Summary of error	
Mean error	0.290563995366
Mean absolute error	2.530298533308
Sums of squares	944.689891134077
Mean square	13.120692932418
Mean percentage error	103.271658235481
Mean abs. perc. error	13.941977653850

**LAMPIRAN I : PENENTUAN MODEL PERAMALAN BAGI DAERAH MERSING**

Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=22.100								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
p(1)	-0.325441	0.124393	-2.61623	0.010883	-0.573536	-0.077347	pass	21.03196
p(2)	-0.342243	0.135790	-2.52039	0.014005	-0.613067	-0.071419	pass	18.56098
Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=21.817								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
p(1)	-0.349403	0.124838	-2.79885	0.006644	-0.598447	-0.100358	pass	22.4199
p(2)	-0.404546	0.142381	-2.84129	0.005902	-0.688589	-0.120504	pass	19.9555
p(3)	-0.211062	0.153963	-1.37087	0.174859	-0.518209	0.096085	fail	8.90390
Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=21.752								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
q(1)	0.591576	0.147035	4.023376	0.000142	0.298397	0.884755	pass	27.36343
Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=19.957								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
q(1)	0.416541	0.114914	3.624797	0.000544	0.187352	0.645730	pass	31.5435
q(2)	0.390041	0.133429	2.923217	0.004663	0.123926	0.656156	pass	21.90847
Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(0,0,3) MS Residual=20.246								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
q(1)	0.415555	0.122992	3.378724	0.001201	0.170193	0.660917	pass	27.47113
q(2)	0.388779	0.144964	2.681901	0.009152	0.099584	0.677974	pass	18.50047
q(3)	0.003565	0.147657	0.024146	0.980806	-0.291002	0.298132	fail	0.163526
Input: MERSING : D(-1) (SEMUA) Transformations: none Model:(3,0,3) MS Residual=20.961								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 66)	p	Lower 95% Conf	Upper 95% Conf	P prob test	t TEST =abs(v3/v2
p(1)	0.448672	1.412799	0.317576	0.751809	-2.37207	3.269417	fail	0.224785
p(2)	0.116031	0.544230	0.213202	0.831826	-0.97056	1.202621	fail	0.39175
p(3)	-0.184079	0.324540	-0.567201	0.572502	-0.83204	0.463885	fail	1.747709
q(1)	0.865442	1.432982	0.603945	0.547951	-1.99560	3.726484	fail	0.42146
q(2)	0.329126	0.839635	0.391987	0.696331	-1.34726	2.005512	fail	0.466853
q(3)	-0.343251	0.613663	-0.559348	0.577818	-1.56847	0.881966	fail	0.911491

	Exponential smoothing: S0=.2221 (SEMUA) No trend, no season ; Alpha=.100 MERSING : D(-1); ARIMA (1,0,0) residuals;
Summary of error	Error
Mean error	0.14959681103
Mean absolute error	3.05072699246
Sums of squares	1835.11022872076
Mean square	25.48764206557
Mean percentage error	103.66584775872
Mean abs. perc. error	31.13645983870
	Exponential smoothing: S0=.2891 (SEMUA) No trend, no season ; Alpha=.100 MERSING : D(-1); ARIMA (2,0,0) residuals;
Summary of error	Error
Mean error	0.21177500229
Mean absolute error	3.01289213583
Sums of squares	1656.72699894751
Mean square	23.01009720760
Mean percentage error	616.62952924464
Mean abs. perc. error	512.75278579916
	Exponential smoothing: S0=.3818 (SEMUA) No trend, no season ; Alpha=.100 MERSING : D(-1); ARIMA (0,0,1) residuals;
Summary of error	Error
Mean error	0.29740703881
Mean absolute error	2.81561338037
Sums of squares	1611.89544145253
Mean square	22.38743668684
Mean percentage error	95.31257910090
Mean abs. perc. error	-29.97589134671
	Exponential smoothing: S0=.3249 (SEMUA) No trend, no season ; Alpha=.100 MERSING : D(-1); ARIMA (0,0,2) residuals;
Summary of error	Error
Mean error	0.31624408597
Mean absolute error	2.83953085830
Sums of squares	1435.17587730342
Mean square	19.93299829588
Mean percentage error	-16.08387536653
Mean abs. perc. error	140.31086964522

## LAMPIRAN J: PENENTUAN MODEL PERAMALAN BAGI DAERAH MUAR

Input: VAR1 : MUAR A; D(-1) (Spreadsheet201 in Workbook11)								
Transformations: none								
Model:(1,0,0) MS Residual=13.221								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P prob. test	t TEST =abs(v3/v2)
p(1)	-0.461221	0.114382	-4.03229	0.000137	-0.689292	-0.233150	pass	35.252827

Input: VAR1 : MUAR A; D(-1) (Spreadsheet201 in Workbook11)								
Transformations: none								
Model:(2,0,0) MS Residual=12.549								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob. test	t TEST =abs(v3/v2)
p(1)	-0.558261	0.120047	-4.65035	0.000015	-0.797688	-0.318835	pass	38.73768
p(2)	-0.273424	0.125700	-2.17521	0.032994	-0.524125	-0.022723	pass	17.30474

Input: MUARA : D(-1) (SEMUA)								
Transformations: none								
Model:(3,0,0) MS Residual=12.728								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	P prob. test	t TEST =abs(v3/v2)
p(1)	-0.552994	0.127056	-4.35235	0.000046	-0.806465	-0.299523	pass	34.25524
p(2)	-0.265751	0.138791	-1.91475	0.059671	-0.542632	0.011131	fail	13.79587
p(3)	0.018205	0.134936	0.13492	0.893069	-0.250985	0.287396	fail	0.999866

Input: VAR1 : MUAR A; D(-1) (Spreadsheet201 in Workbook11)								
Transformations: none								
Model:(0,0,1) MS Residual=12.009								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	P prob. test	t TEST =abs(v3/v2)
q(1)	0.689086	0.120443	5.721244	0.000000	0.448929	0.929243	pass	47.50153

Input: MUARA : D(-1) (SEMUA)								
Transformations: none								
Model:(0,0,3) MS Residual=12.130								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	p Prob Test	t TEST =abs(v3/v2)
q(1)	0.693174	0.137604	5.037444	0.000004	0.418661	0.967687	pass	36.60821
q(2)	-0.063671	0.224768	-0.283275	0.777814	-0.512072	0.384729	fail	1.260299
q(3)	0.131672	0.151737	0.867760	0.388534	-0.171036	0.434379	fail	5.71883

Input: MUARA : D(-1) (SEMUA)								
Transformations: none								
Model:(0,0,2) MS Residual=12.090								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	P prob. test	t TEST =abs(v3/v2)
q(1)	0.646083	0.121954	5.297771	0.000001	0.402854	0.889312	pass	43.44081
q(2)	0.090888	0.126396	0.719071	0.474491	-0.161201	0.342977	fail	5.689027

	Exponential smoothing: S0=-.056 (Spreadsheet201 in Workbook11) No trend, no season ; Alpha=.100 VAR1 : MUAR A; D(-1); ARIMA (1,0,0) residuals;
Summary of error	Error
Mean error	0.10781233816
Mean absolute error	2.87298417416
Sums of squares	1021.75223797620
Mean square	14.19100330522
Mean percentage error	108.01739964676
Mean abs. perc. error	22.59810009580

	Exponential smoothing: S0=-.074 (Spreadsheet201 in Workbook11) No trend, no season ; Alpha=.100 VAR1 : MUAR A; D(-1); ARIMA (2,0,0) residuals;
Summary of error	Error
Mean error	0.13295759800
Mean absolute error	2.85273530106
Sums of squares	947.13988689008
Mean square	13.15472065125
Mean percentage error	100.67891128294
Mean abs. perc. error	16.98600955147

	Exponential smoothing: S0=-.224 (Spreadsheet201 in Workbook11) No trend, no season ; Alpha=.100 VAR1 : MUAR A; D(-1); ARIMA (0,0,1) residuals;
Summary of error	Error
Mean error	0.15607104091
Mean absolute error	2.76901051463
Sums of squares	900.31479262690
Mean square	12.50437211981
Mean percentage error	126.13418503448
Mean abs. perc. error	15.67143299902

	Exponential smoothing: S0=-.322 (Spreadsheet201 in Workbook11) No trend, no season ; Alpha=.100 VAR1 : MUAR A; D(-1); ARIMA (2,0,3) residuals;
Summary of error	Error
Mean error	0.150080267977
Mean absolute error	2.513807380024
Sums of squares	785.345307116300
Mean square	10.907573709949
Mean percentage error	133.135915115835
Mean abs. perc. error	57.013250270146



**LAMPIRAN K : PENENTUAN MODEL PERAMALAN BAGI DAERAH  
PONTIAN**

Input: PONTIAN : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=17.957								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2)
p(1)	-0.314473	0.132751	-2.36889	0.020605	-0.579237	-0.049709	pass	17.8446
p(2)	-0.224542	0.134288	-1.67209	0.098970	-0.492371	0.043287	fail	12.45156

Input: PONTIAN : D(-1) (SEMUA.sta) Transformations: none Model:(1,0,0) MS Residual=18.421								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2)
p(1)	-0.271763	0.131931	-2.05988	0.043077	-0.534826	-0.008700	pass	15.61334

Input: PONTIAN : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=17.899								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2)
p(1)	-0.358711	0.138519	-2.58962	0.011711	-0.635048	-0.082373	pass	18.6951
p(2)	-0.259760	0.137855	-1.88430	0.063738	-0.534774	0.015253	fail	13.6686
p(3)	-0.155388	0.141287	-1.09980	0.275242	-0.437248	0.126473	fail	7.78413

Input: PONTIAN : D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=17.445								
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2)
q(1)	0.558238	0.189191	2.950656	0.004293	0.181002	0.935474	pass	15.59617

	Exponential smoothing: S0=.0927 (SEMUA) No trend, no season ; Alpha=.100 PONTIAN : D(-1); ARIMA (0,0,1) residuals;
Summary of error	Error
Mean error	0.27330871112
Mean absolute error	3.16700120365
Sums of squares	1304.25061656156
Mean square	18.11459189669
Mean percentage error	113.10189670563
Mean abs. perc. error	15.96540442106

	Exponential smoothing: S0=-.140 (SEMUA) No trend, no season ; Alpha=.100 PONTIAN : D(-1); ARIMA (1,0,1) residuals;
Summary of error	Error
Mean error	0.29811001533
Mean absolute error	2.93754478809
Sums of squares	1207.00497296830
Mean square	16.76395795789
Mean percentage error	82.09838041441
Mean abs. perc. error	14.52056249268

**LAMPIRAN L: PENENTUAN MODEL PERAMALAN BAGI  
DAERAH SEGAMAT**

	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(1,0,0) MS Residual=12.361							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
p(1)	-0.268091	0.115203	-2.32712	0.022815	-0.497799	-0.038383	pass	20.20025
	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(2,0,0) MS Residual=11.836							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
p(1)	-0.333503	0.117287	-2.84349	0.005845	-0.567424	-0.099583	pass	24.24394
p(2)	-0.239972	0.118639	-2.02271	0.046925	-0.476591	-0.003354	pass	17.04925
	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(3,0,0) MS Residual=10.757							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
p(1)	-0.406265	0.114782	-3.53946	0.000723	-0.635249	-0.177282	pass	30.83642
p(2)	-0.338034	0.118371	-2.85571	0.005668	-0.574178	-0.101890	pass	24.12506
p(3)	-0.345607	0.122933	-2.81135	0.006417	-0.590850	-0.100363	pass	22.86901
	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(0,0,1) MS Residual=10.560							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 71)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
q(1)	0.745969	0.093651	7.965421	0.000000	0.559234	0.932703	pass	85.05443
	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(0,0,2) MS Residual=10.014							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 70)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
q(1)	0.549616	0.108733	5.054742	0.000003	0.332755	0.766476	pass	46.4878
q(2)	0.239897	0.104315	2.299741	0.024449	0.031848	0.447947	pass	22.04614
	Input: SEGAMAT : D(-1) (SEMUA) Transformations: none Model:(0,0,3) MS Residual=10.115							
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 69)	p	Lower 95% Conf	Upper 95% Conf	p Prob. test	t Test =abs(v3/v2
q(1)	0.514157	0.129253	3.977911	0.000169	0.256304	0.772009	pass	30.77617
q(2)	0.219045	0.117036	1.871607	0.065500	-0.014435	0.452526	fail	15.99171
q(3)	0.070677	0.126846	0.557190	0.579201	-0.182373	0.323727	fail	4.392658

	Exponential smoothing: S0=-.037 (SEMUA) No trend, no season ; Alpha=.100 SEGAMAT : D(-1); ARIMA (1,0,0) residuals;
	Error
Summary of error	
Mean error	0.038285486124
Mean absolute error	2.758635118862
Sums of squares	963.090303133953
Mean square	13.376254210194
Mean percentage error	140.305202149623
Mean abs. perc. error	33.881749922445

	Exponential smoothing: S0=-.027 (SEMUA) No trend, no season ; Alpha=.100 SEGAMAT : D(-1); ARIMA (2,0,0) residuals;
	Error
Summary of error	
Mean error	0.067138841199
Mean absolute error	2.775182120211
Sums of squares	904.941328700632
Mean square	12.568629565287
Mean percentage error	15.555531665810
Mean abs. perc. error	-47.885489045498

	Exponential smoothing: S0=-.060 (SEMUA) No trend, no season ; Alpha=.100 SEGAMAT : D(-1); ARIMA (3,0,0) residuals;
	Error
Summary of error	
Mean error	0.072712893396
Mean absolute error	2.658823711462
Sums of squares	805.544504686867
Mean square	11.188118120651
Mean percentage error	107.183561026873
Mean abs. perc. error	1.367849413039

	Exponential smoothing: S0=-.101 (SEMUA) No trend, no season ; Alpha=.100 SEGAMAT : D(-1); ARIMA (2,0,2) residuals;
	Error
Summary of error	
Mean error	0.098195724248
Mean absolute error	2.455010535751
Sums of squares	708.008354787696
Mean square	9.833449372051
Mean percentage error	26.819525861233
Mean abs. perc. error	-75.621469422845

## LAMPIRAN M1

Larian latihan model rangkaian


```
>>
Tarikh_Waktu =
05-Sep-2004 07:46:37

TRAIINGDM, Epoch 0/10000, MSE 7.30005/0.01, Gradient 6.37743/1e-010
TRAIINGDM, Epoch 92/10000, MSE 0.00966259/0.01, Gradient 0.0161486/1e-010
TRAIINGDM, Performance goal met.

Nilai Mean Square Error (MSE) Latihan ialah 0.009663
Nilai Mean Square Error (MSE) Validasi ialah 0.008263
```

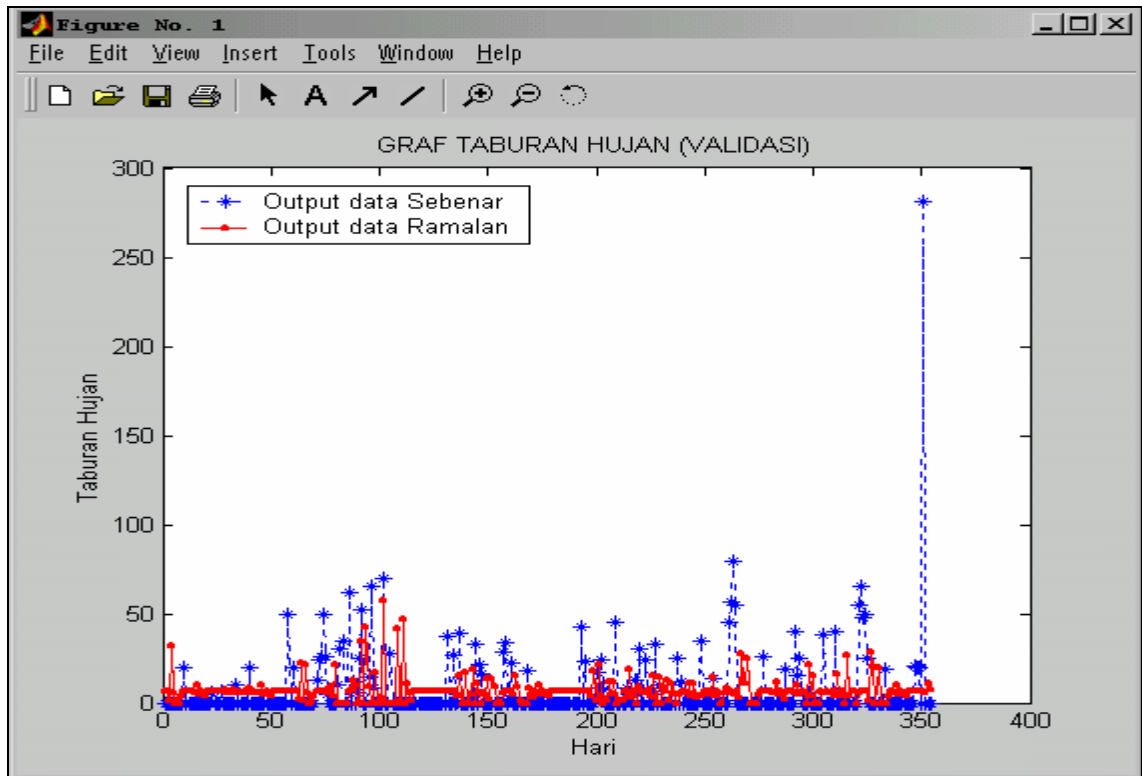
## LAMPIRAN M2

Rajah pencapaian larian latihan



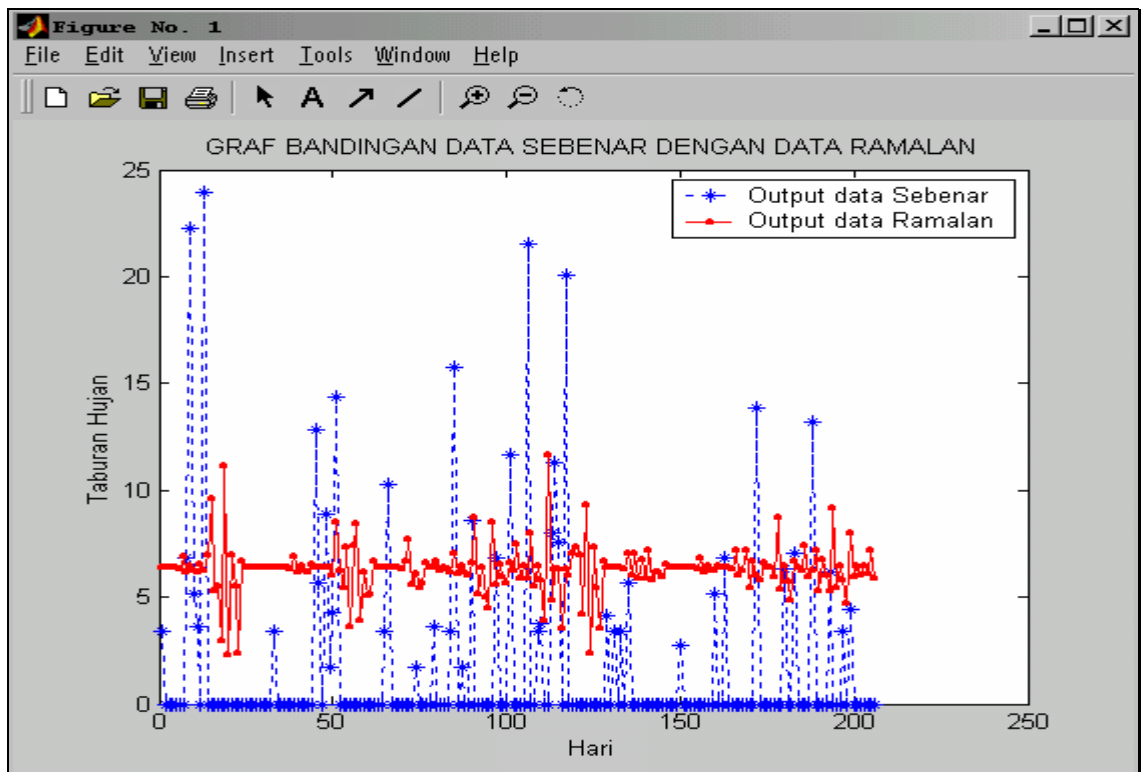
### LAMPIRAN M3

Graf taburan hujan (validasi)



### LAMPIRAN M4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN N**

Stesen Ldg. Union Yong Peng Daerah Batu Pahat.

## LAMPIRAN N1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
05-Sep-2004 09:24:29

TRAIINGDM, Epoch 0/10000, MSE 3.94556/0.015, Gradient 3.7241/1e-010  
TRAIINGDM, Epoch 100/10000, MSE 0.017216/0.015, Gradient 0.00754954/1e-010  
TRAIINGDM, Epoch 168/10000, MSE 0.0149986/0.015, Gradient 0.00471691/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.014999  
Nilai Mean Square Error(MSE) Validasi ialah 0.021370

## LAMPIRAN N2


Rajah pencapaian larian latihan





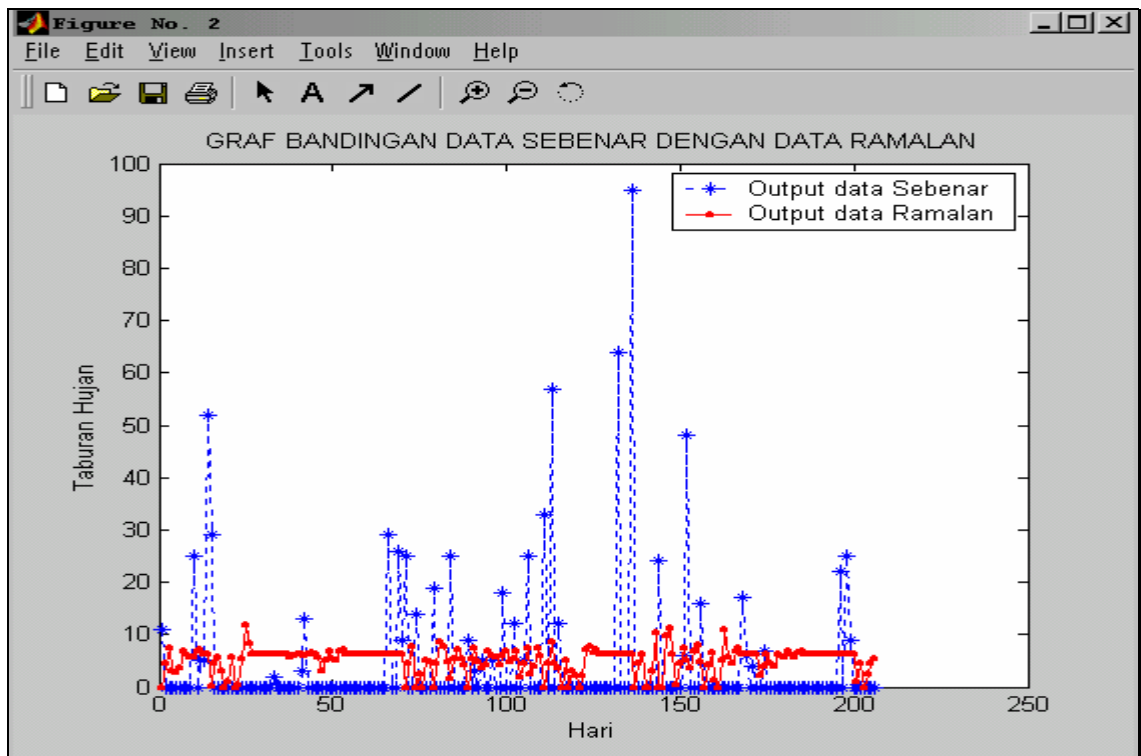
### LAMPIRAN N3

Graf taburan hujan (validasi)



### LAMPIRAN N4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN O**

Stesen Ldg. Senai Daerah Johor Bahru.

## LAMPIRAN 01

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
05-Sep-2004 11:38:57

TRAINGDY, Epoch 0/10000, MSE 1.25463/0.01, Gradient 1.82681/1e-006  
TRAINGDY, Epoch 65/10000, MSE 0.00999895/0.01, Gradient 0.00884343/1e-006  
TRAINGDY, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009999  
Nilai Mean Square Error(MSE) Validasi ialah 0.014798


## LAMPIRAN 02

Rajah pencapaian larian latihan




### LAMPIRAN 03

Graf taburan hujan (validasi)



### LAMPIRAN 04

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN P**

Stesen Ldg. Sg. Tiram Daerah Johor Bahru.

## LAMPIRAN P1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
05-Sep-2004 12:01:18

TRAIINGDM, Epoch 0/10000, MSE 2.72958/0.01, Gradient 2.7923/1e-010  
TRAIINGDM, Epoch 100/10000, MSE 0.0266415/0.01, Gradient 0.0277713/1e-010  
TRAIINGDM, Epoch 200/10000, MSE 0.0210958/0.01, Gradient 0.020548/1e-010  
TRAIINGDM, Epoch 300/10000, MSE 0.0175467/0.01, Gradient 0.0169728/1e-010  
TRAIINGDM, Epoch 400/10000, MSE 0.0150444/0.01, Gradient 0.0145349/1e-010  
TRAIINGDM, Epoch 500/10000, MSE 0.0131688/0.01, Gradient 0.0127437/1e-010  
TRAIINGDM, Epoch 600/10000, MSE 0.0117064/0.01, Gradient 0.0113459/1e-010  
TRAIINGDM, Epoch 700/10000, MSE 0.010536/0.01, Gradient 0.0102069/1e-010  
TRAIINGDM, Epoch 754/10000, MSE 0.00999775/0.01, Gradient 0.00967148/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009998  
Nilai Mean Square Error(MSE) Validasi ialah 0.019315


## LAMPIRAN P2

Rajah pencapaian larian latihan



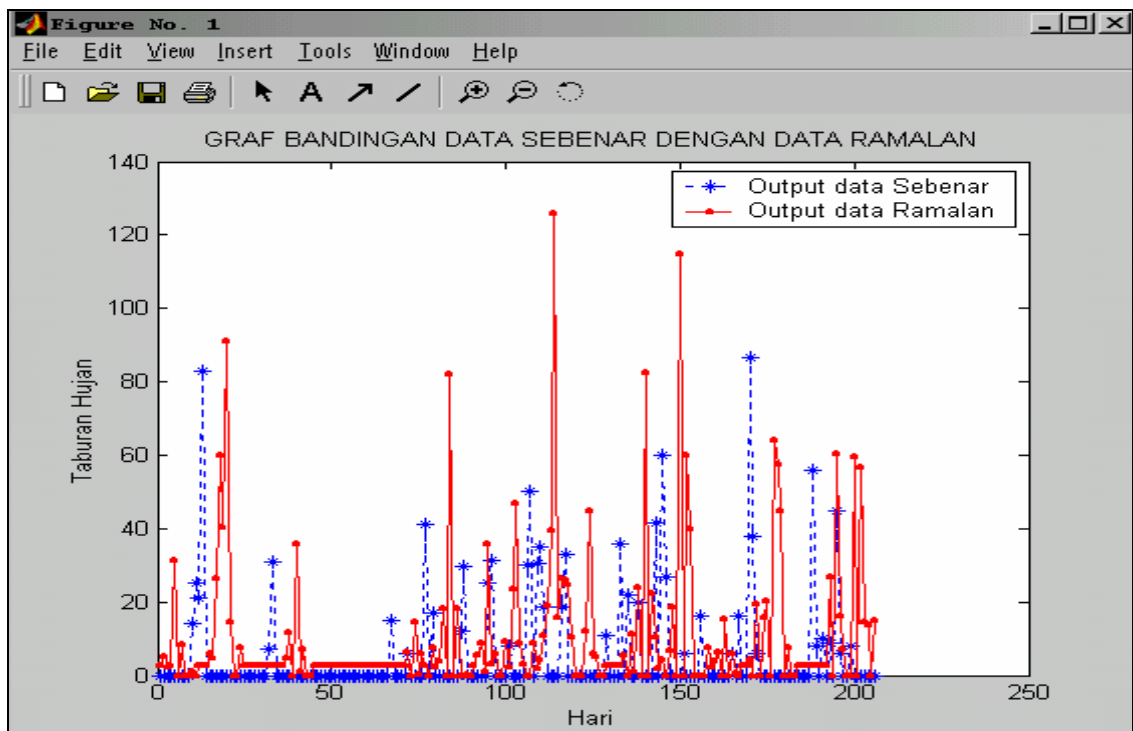
### LAMPIRAN P3

Graf taburan hujan (validasi)



### LAMPIRAN P4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN Q**

Stesen Ldg. Simpang Renggam Daerah Kluang.



## LAMPIRAN Q1

Larian latihan model rangkaian


Tarikh\_Waktu =  
06-Sep-2004 23:43:46

TRAININGM, Epoch 0/10000, MSE 1.65376/0.015, Gradient 2.28628/1e-010  
TRAININGM, Epoch 150/10000, MSE 0.0149894/0.015, Gradient 0.00941544/1e-010  
TRAININGM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.014989  
Nilai Mean Square Error(MSE) Validasi ialah 0.018316


## LAMPIRAN Q2

Rajah pencapaian larian latihan



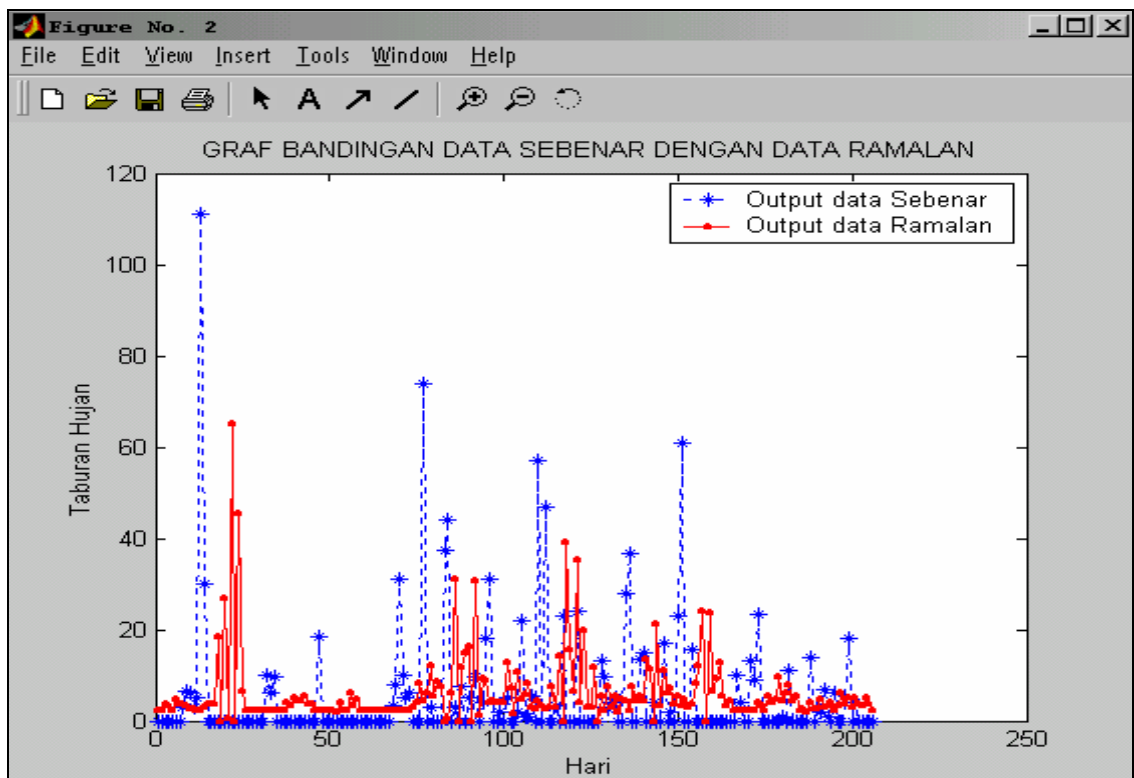
### LAMPIRAN Q3

Graf taburan hujan (validasi)



### LAMPIRAN Q4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN R**

Stesen Ldg. Ulu Paloh Daerah Kluang

## LAMPIRAN R1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
05-Sep-2004 13:15:22

TRAIINGDM, Epoch 0/10000, MSE 1.26461/0.01, Gradient 2.20103/1e-010  
TRAIINGDM, Epoch 100/10000, MSE 0.015108/0.01, Gradient 0.0129216/1e-010  
TRAIINGDM, Epoch 200/10000, MSE 0.0136185/0.01, Gradient 0.011493/1e-010  
TRAIINGDM, Epoch 300/10000, MSE 0.0124329/0.01, Gradient 0.0102887/1e-010  
TRAIINGDM, Epoch 400/10000, MSE 0.0114769/0.01, Gradient 0.00927036/1e-010  
TRAIINGDM, Epoch 500/10000, MSE 0.010696/0.01, Gradient 0.00840631/1e-010  
TRAIINGDM, Epoch 600/10000, MSE 0.0100501/0.01, Gradient 0.00767063/1e-010  
TRAIINGDM, Epoch 609/10000, MSE 0.00999749/0.01, Gradient 0.00760995/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009997  
Nilai Mean Square Error(MSE) Validasi ialah 0.010042


## LAMPIRAN R2

Rajah pencapaian larian latihan



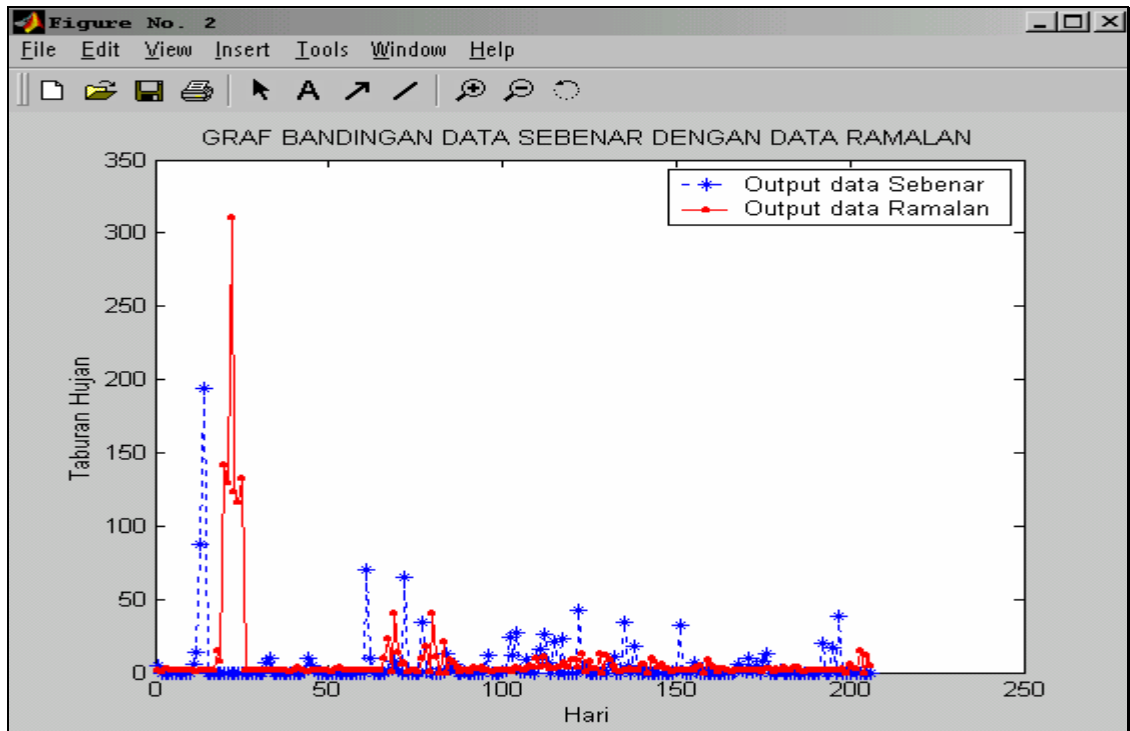
### LAMPIRAN R3

Graf taburan hujan (validasi)



### LAMPIRAN R4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN S**

Stesen Ldg. Getah Malaya Daerah Kota Tinggi.

## LAMPIRAN S1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
05-Sep-2004 14:07:58

TRAIINGDM, Epoch 0/10000, MSE 2.76974/0.01, Gradient 2.86452/1e-010  
TRAIINGDM, Epoch 100/10000, MSE 0.0196203/0.01, Gradient 0.0221836/1e-010  
TRAIINGDM, Epoch 200/10000, MSE 0.0167902/0.01, Gradient 0.0152162/1e-010  
TRAIINGDM, Epoch 300/10000, MSE 0.0147542/0.01, Gradient 0.0131934/1e-010  
TRAIINGDM, Epoch 400/10000, MSE 0.0132002/0.01, Gradient 0.0116362/1e-010  
TRAIINGDM, Epoch 500/10000, MSE 0.011976/0.01, Gradient 0.0104087/1e-010  
TRAIINGDM, Epoch 600/10000, MSE 0.0109863/0.01, Gradient 0.00941778/1e-010  
TRAIINGDM, Epoch 700/10000, MSE 0.0101693/0.01, Gradient 0.00859958/1e-010  
TRAIINGDM, Epoch 724/10000, MSE 0.00999398/0.01, Gradient 0.0084237/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009994  
Nilai Mean Square Error(MSE) Validasi ialah 0.013507


## LAMPIRAN S2

Rajah pencapaian larian latihan




### LAMPIRAN S3

Graf taburan hujan (validasi)



### LAMPIRAN S4

Graf bandingan data sebenar dengan data ramalan





## **LAMPIRAN T**

Stesen Rancangan Ulu Sebol Daerah Kota Tinggi.

## LAMPIRAN T1

Larian latihan model rangkaian

>>

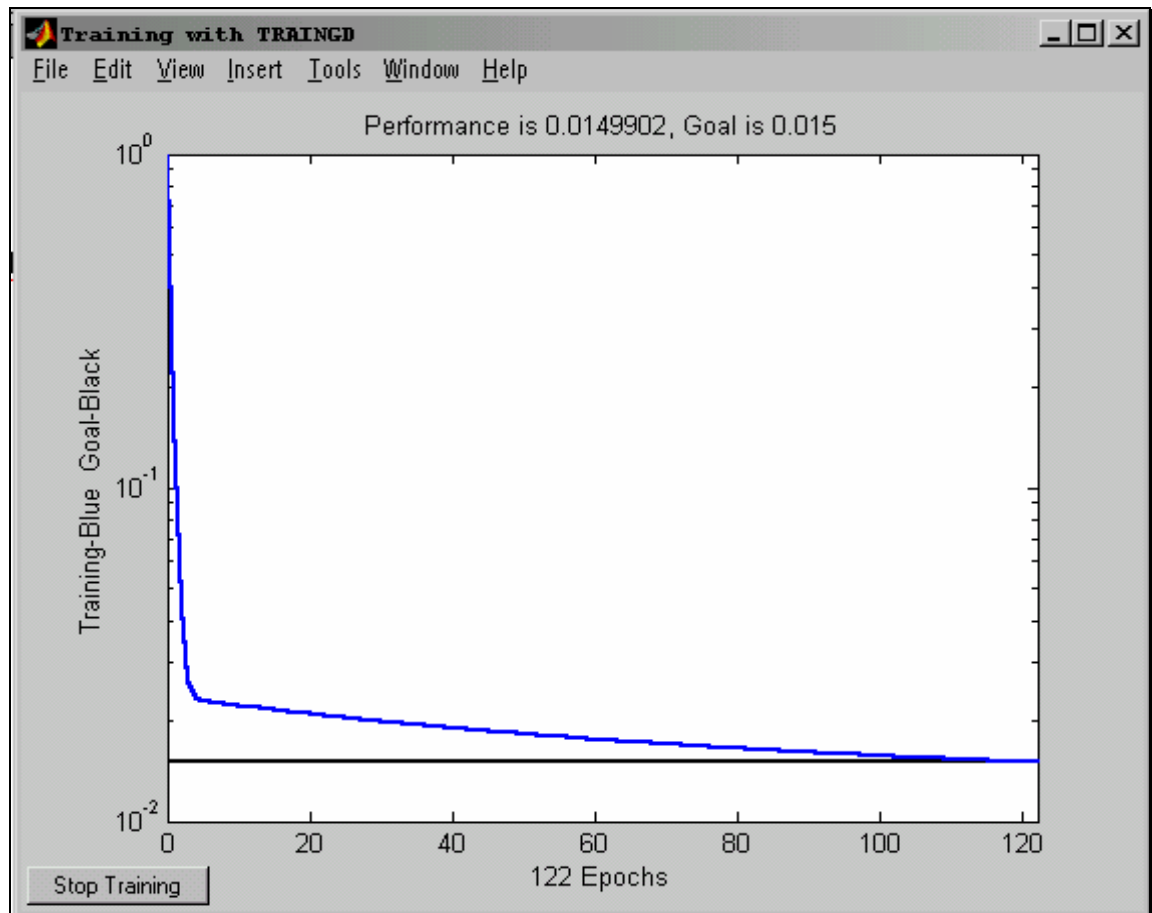
Tarikh\_Waktu =  
07-Sep-2004 07:00:59

TRAINGD, Epoch 0/10000, MSE 0.980819/0.015, Gradient 1.53939/1e-010  
TRAINGD, Epoch 122/10000, MSE 0.0149902/0.015, Gradient 0.00752349/1e-010  
TRAINGD, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.014990  
Nilai Mean Square Error(MSE) Validasi ialah 0.007447


## LAMPIRAN T2

Rajah pencapaian larian latihan




### LAMPIRAN T3

Graf taburan hujan (validasi)



### LAMPIRAN T4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN U**

Stesen Ibu Bekalan Kahang Daerah Mersing.

## LAMPIRAN U1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
06-Sep-2004 16:35:00

TRAIINGDX, Epoch 0/10000, MSE 2.13394/0.015, Gradient 3.72072/1e-006  
TRAIINGDX, Epoch 110/10000, MSE 0.0148594/0.015, Gradient 0.00424917/1e-006  
TRAIINGDX, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.014859  
Nilai Mean Square Error(MSE) Validasi ialah 0.013242


## LAMPIRAN U2

Rajah pencapaian larian latihan



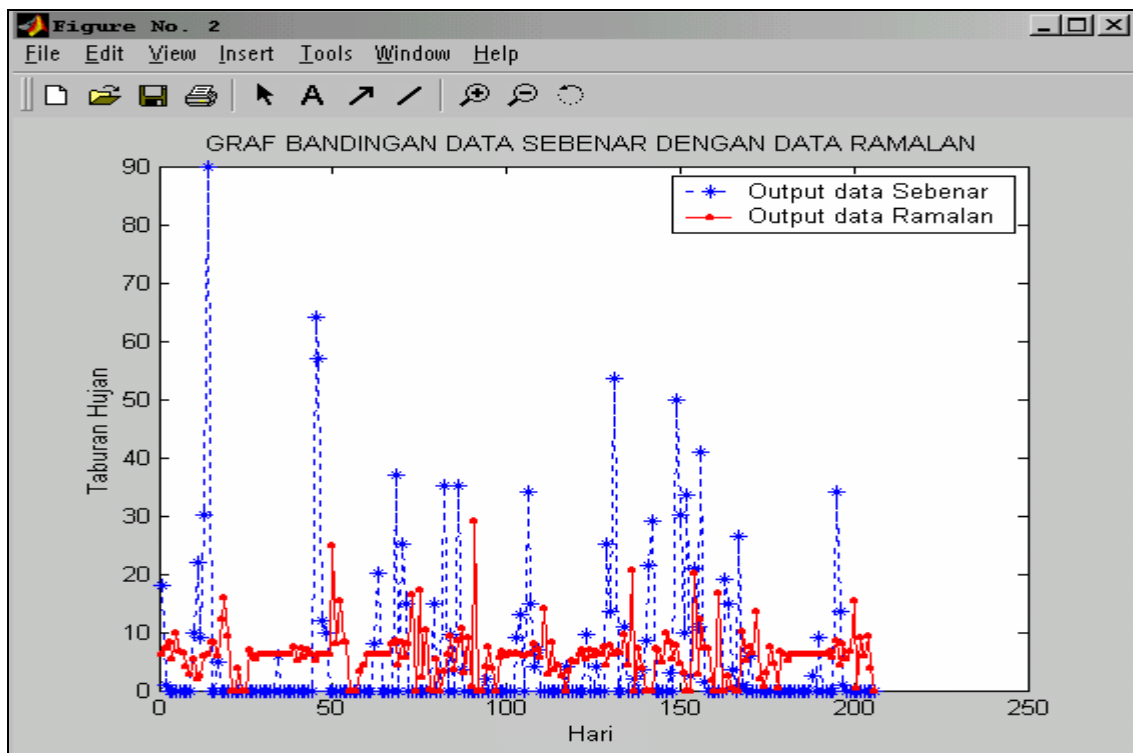
### LAMPIRAN U3

Graf taburan hujan (validasi)



### LAMPIRAN U4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN V**

Stesen Pusat Pertanian Endau Daerah Mersing.

## LAMPIRAN V1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
06-Sep-2004 19:57:58

TRAIINGDM, Epoch 0/10000, MSE 4.06064/0.01, Gradient 3.81624/1e-010  
TRAIINGDM, Epoch 263/10000, MSE 0.00999858/0.01, Gradient 0.00341412/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009999  
Nilai Mean Square Error(MSE) Validasi ialah 0.011371

## LAMPIRAN V2


Rajah pencapaian larian latihan





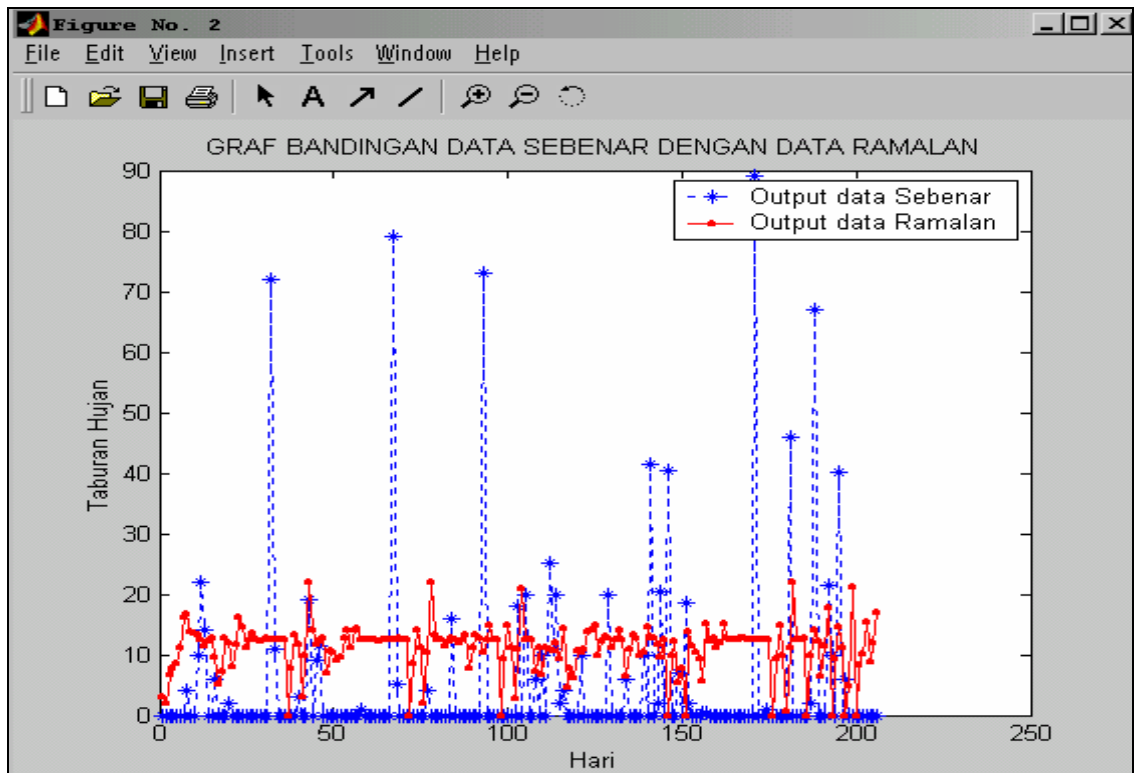
### LAMPIRAN V3

Graf taburan hujan (validasi)



### LAMPIRAN V4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN W**

Stesen Ldg. Temiang Renchong Daerah Muar

## LAMPIRAN W1

Larian latihan model rangkaian


```
>>
Tarikh_Waktu =
07-Sep-2004 14:54:34

TRAIINGDX, Epoch 0/50000, MSE 0.502641/0.03, Gradient 1.10598/1e-006
TRAIINGDX, Epoch 88/50000, MSE 0.0297551/0.03, Gradient 0.00589198/1e-006
TRAIINGDX, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.029755
Nilai Mean Square Error(MSE) Validasi ialah 0.036014
```


## LAMPIRAN W2

Rajah pencapaian larian latihan




### LAMPIRAN W3

Graf taburan hujan (validasi)



### LAMPIRAN W4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN X**

Stesen Ldg. Gomali Batu Enam Daerah Muar

## LAMPIRAN X1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
07-Sep-2004 15:40:40

TRAINGD, Epoch 0/10000, MSE 0.978167/0.025, Gradient 1.52159/1e-010  
TRAINGD, Epoch 116/10000, MSE 0.0249846/0.025, Gradient 0.00799547/1e-010  
TRAINGD, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.024985  
Nilai Mean Square Error(MSE) Validasi ialah 0.010529


## LAMPIRAN X2

Rajah pencapaian larian latihan



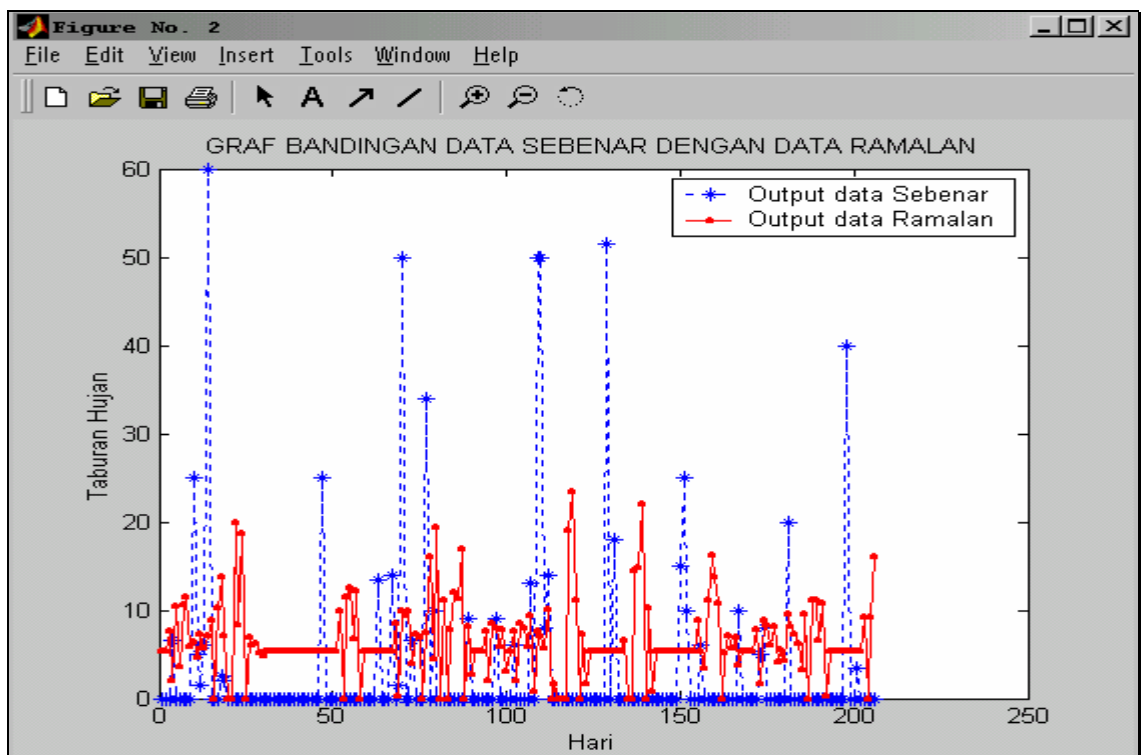
### LAMPIRAN X3

Graf taburan hujan (validasi)



### LAMPIRAN X4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN Y**

Stesen Ldg. Getah Kukup Daerah Pontian.



## LAMPIRAN Y1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
06-Sep-2004 13:17:50

TRAINGDM, Epoch 0/10000, MSE 2.23342/0.01, Gradient 2.97631/1e-010  
TRAINGDM, Epoch 254/10000, MSE 0.00999356/0.01, Gradient 0.00291551/1e-010  
TRAINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009994  
Nilai Mean Square Error(MSE) Validasi ialah 0.009054


## LAMPIRAN Y2

Rajah pencapaian larian latihan



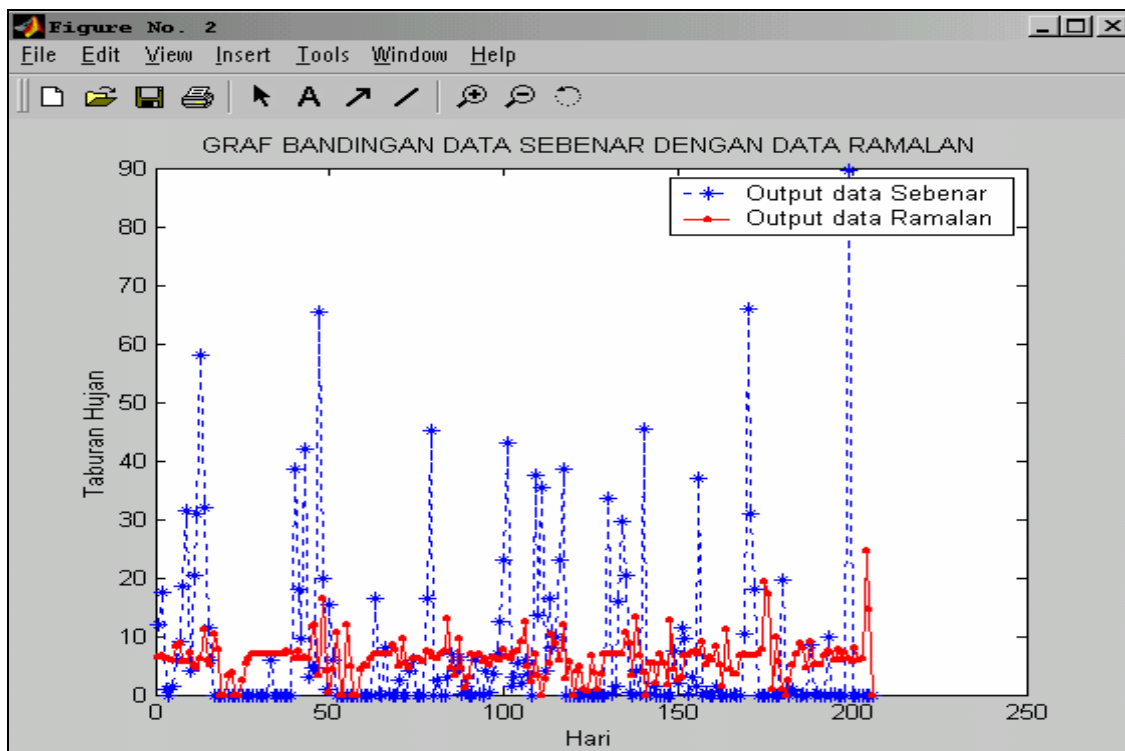
### LAMPIRAN Y3

Graf taburan hujan (validasi)



### LAMPIRAN Y4

Graf bandingan data sebenar dengan data ramalan



## **LAMPIRAN Z**

Stesen Pintu Pasang Surut Senggarang Daerah Pontian

## LAMPIRAN Z1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
06-Sep-2004 14:27:06

TRAIINGDM, Epoch 0/10000, MSE 2.24673/0.01, Gradient 2.97507/1e-010  
TRAIINGDM, Epoch 82/10000, MSE 0.00954784/0.01, Gradient 0.00867391/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009548  
Nilai Mean Square Error(MSE) Validasi ialah 0.009309


## LAMPIRAN Z2

Rajah pencapaian larian latihan



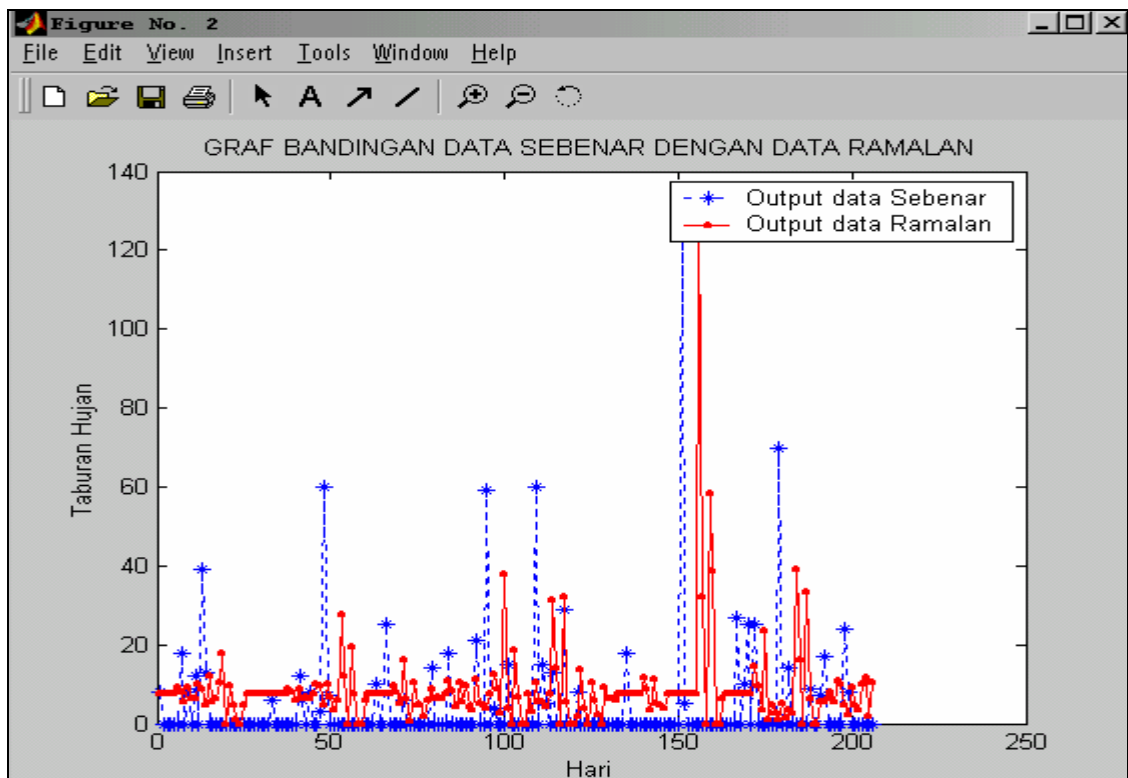
### LAMPIRAN Z3

Graf taburan hujan (validasi)



### LAMPIRAN Z4

Graf bandingan bata sebenar dengan data ramalan



## **LAMPIRAN AA**

Stesen Ldg. Segamat Daerah Segamat

## LAMPIRAN AA1

Larian latihan model rangkaian

>>


Tarikh\_Waktu =  
06-Sep-2004 09:33:26

TRAIINGDM, Epoch 0/10000, MSE 2.76033/0.01, Gradient 2.88003/1e-010  
TRAIINGDM, Epoch 300/10000, MSE 0.0146277/0.01, Gradient 0.011941/1e-010  
TRAIINGDM, Epoch 600/10000, MSE 0.0113798/0.01, Gradient 0.00895565/1e-010  
TRAIINGDM, Epoch 801/10000, MSE 0.00999676/0.01, Gradient 0.00761599/1e-010  
TRAIINGDM, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.009997  
Nilai Mean Square Error(MSE) Validasi ialah 0.020594


## LAMPIRAN AA2

Rajah pencapaian larian latihan



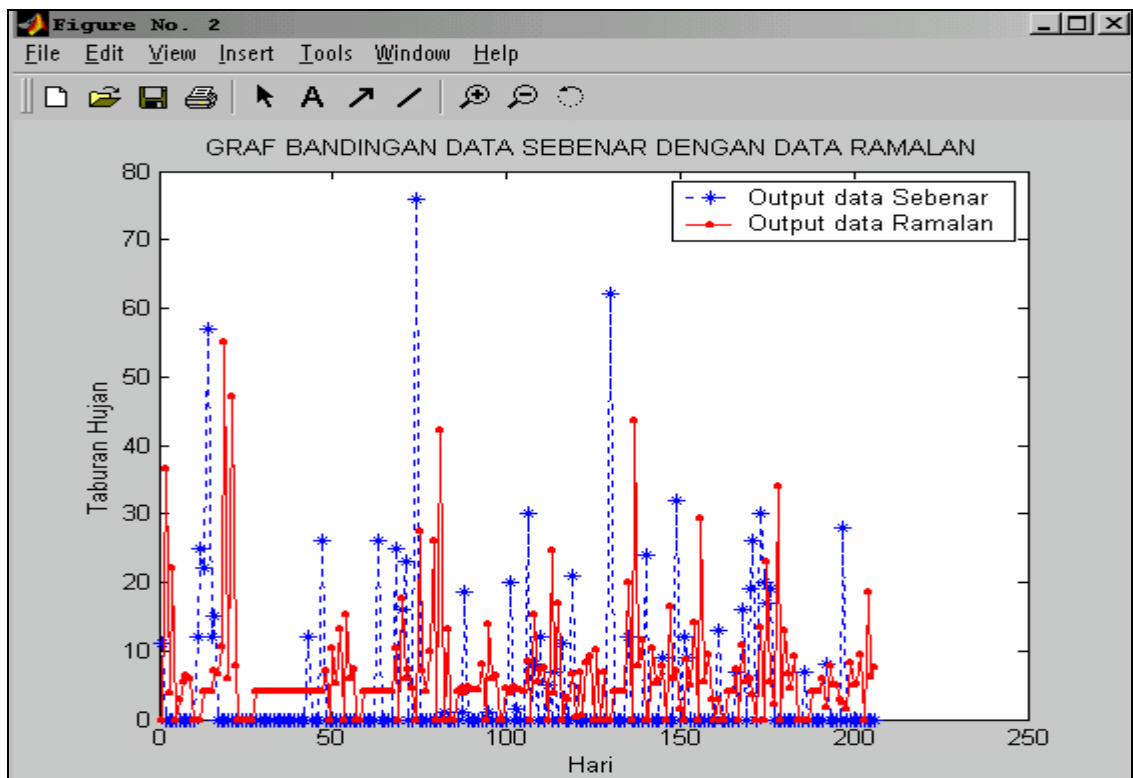
## LAMPIRAN AA3

Graf taburan hujan (validasi)



#### LAMPIRAN AA4

Graf bandingan data sebenar dengan data ramalan





## **LAMPIRAN AB**

Stesen Ldg. Mados Sermin Daerah Segamat

## LAMPIRAN AB1

Larian latihan model rangkaian


```
>>
Tarikh_Waktu =
07-Sep-2004 21:17:00

TRAINGDY, Epoch 0/10000, MSE 0.438216/0.02, Gradient 1.0743/1e-006
TRAINGDY, Epoch 86/10000, MSE 0.0199957/0.02, Gradient 0.00529446/1e-006
TRAINGDY, Performance goal met.

Nilai Mean Square Error(MSE) Latihan ialah 0.019996
Nilai Mean Square Error(MSE) Validasi ialah 0.019832
```


## LAMPIRAN AB2

Rajah pencapaian larian latihan



### LAMPIRAN AB3

Graf taburan hujan (validasi)



## LAMPIRAN AB4

Graf bandingan data sebenar dengan data ramalan

