

**ANALISIS STRUKTUR TERBAIK ALGORITMA *ARTIFICIAL NEURAL NETWORK* UNTUK MEMPREDIKSI *DAILY INFLOW* BENDUNGAN BATU TEGI MENGGUNAKAN METODE *BACKPROPAGATION***

(Skripsi)

Oleh

**INTAN INDRIYANI  
NPM. 1817031052**



**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2022**

## **ABSTRACT**

### **THE BEST STRUCTURAL ANALYSIS OF THE ARTIFICIAL NEURAL NETWORK ALGORITHM TO PREDICT THE INFLOW DISCHARGE OF THE BATU TEGI DAM USING THE BACKPROPAGATION METHOD**

**By**

**INTAN INDRIYANI**

Time Series is an observation on a variable from the past and recorded sequentially according to the time sequence with a fixed period. Data from the past inflow discharge of the Batu Tegi dam is one of the time series data. Dams are one of the resources that have an important role in various sectors of life. The purpose of this study is to explain the procedure for forming a Feedforward Neural Network (FFNN) model with the Backpropagation Algorithm and predict the inflow discharge using this model. The FFNN model with the Backpropagation algorithm is applied to the inflow discharge data from January 2018 to December 2020 with the input variables being inflow discharge Lag-1 Lag-2, Lag-3, Lag-4, Lag-5, Lag-6, Lag-7, Lag-9, and Lag-10. The best network structure obtained is with 9 input neurons, 9 neurons in the first hidden layer, and 4 neurons in the second hidden layer, a threshold value of 0.01 using the Sigmoid activation function. By using the best network structure, the MSE value is 0.153388 and the accuracy value is 99.6687%. The results of the inflow discharge forecasting for the next period on January 1, 2021, amounted to 29.62063 m<sup>3</sup>/s, for further forecasting it is done in the same way.

**Keywords:** Feedforward Neural Network, Backpropagation, predict, inflow discharge

## ABSTRAK

### **ANALISIS STRUKTUR TERBAIK ALGORITMA *ARTIFICIAL NEURAL NETWORK* UNTUK MEMPREDIKSI *DAILY INFLOW* BENDUNGAN BATU TEGI MENGGUNAKAN METODE *BACKPROPAGATION***

Oleh

**INTAN INDRIYANI**

*Time Series* merupakan pengamatan pada variabel tertentu dari masa lalu dan dicatat secara berurutan sesuai dengan urutan waktu dan periode yang tetap. Data dari waktu lampau debit *inflow* bendungan Batu Tegi merupakan salah satu data *time series*. Bendungan merupakan salah satu sumber daya yang berperan penting di setiap sektor kehidupan. Penelitian ini bertujuan untuk menjelaskan prosedur pembentukan model *Feedforward Neural Network* (FFNN) dengan Algoritma *Backpropagation* dan meramalkan debit *inflow* menggunakan model tersebut. Model FFNN dengan algoritma *Backpropagation* ini diterapkan pada data debit *inflow* bulan Januari 2018 sampai Desember 2020 dengan variabel inputnya yaitu debit *inflow* Lag-1 Lag-2, Lag-3, Lag-4, Lag-5, Lag-6, Lag-7, Lag-9, dan Lag-10. Struktur jaringan terbaik yang diperoleh adalah dengan 9 *neuron input*, 9 *neuron* pada *hidden layer* pertama, dan 4 *neuron* pada *hidden layer* kedua nilai *threshold* 0,01 dengan menggunakan fungsi aktivasi Sigmoid. Dengan menggunakan struktur jaringan terbaik didapatkan nilai MSE sebesar 0,153388 dan nilai akurasi sebesar 99,6687%. Hasil peramalan debit *inflow* untuk periode berikutnya yaitu tanggal 1 Januari 2021 sebesar 29,62063 m<sup>3</sup>/det, untuk peramalan selanjutnya dilakukan dengan cara yang sama.

**Kata kunci:** *Feedforward Neural Network*, *Backpropagation*, peramalan, debit *inflow*.

**ANALISIS STRUKTUR TERBAIK ALGORITMA *ARTIFICIAL NEURAL NETWORK* UNTUK MEMPREDIKSI *DAILY INFLOW* BENDUNGAN BATU TEGI MENGGUNAKAN METODE *BACKPROPAGATION***

**Oleh**

**INTAN INDRIYANI**

**Skripsi**

Sebagai Salah Satu Syarat Untuk Mencapai Gelar  
**SARJANA MATEMATIKA**

Pada

Jurusan Matematika  
Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2022**

Judul Skripsi : **ANALISIS STRUKTUR TERBAIK ALGORITMA  
ARTIFICIAL NEURAL NETWORK UNTUK  
MEMPREDIKSI *DAILY INFLOW* BENDUNGAN  
BATU TEGI MENGGUNAKAN METODE  
*BACKPROPAGATION***

Nama mahasiswa : **Intan Indriyani**

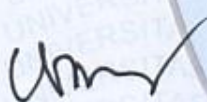
Nomor Pokok Mahasiswa : **1817031052**


Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

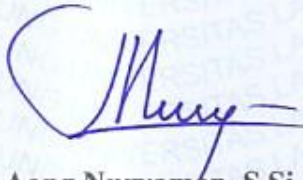


1. Komisi Pembimbing

  
**Ir. Warsono, M.S., Ph.D.**  
NIP. 19630216198703 1 001

  
**Dr. Ir. Slamet Budi Yuwono, M.S.**  
NIP. 19641223199403 1 003

2. Ketua Jurusan Matematika

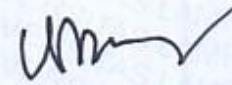
  
**Dr. Aang Nuryaman, S.Si., M.Si.**  
NIP. 19740316 200501 1 001



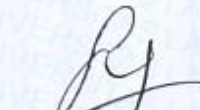
MENGESAHKAN

1. Tim Penguji

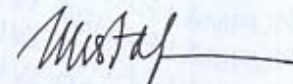
Ketua : Ir. Warsono, M.S., Ph.D.

  
.....

Sekretaris : Dr. Ir. Slamet Budi Yuwono, M.S.

  
.....

Anggota : Prof. Drs. Mustofa Usman, M.A., Ph.D.

  
.....

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng Saipho Dwi Yuwono, M.T.

NIP. 197107107052000031001

Tanggal Lulus Ujian Skripsi : 15 Juni 2022

## PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Intan Indriyani**

Nomor Pokok Mahasiswa : **1817031052**

Jurusan : **Matematika**

Judul Skripsi : **ANALISIS STRUKTUR TERBAIK  
ALGORITMA *ARTIFICIAL NEURAL  
NETWORK* UNTUK MEMPREDIKSI *DAILY  
INFLOW* BENDUNGAN BATU TEGI  
MENGUNAKAN METODE  
*BACKPROPAGATION***

Dengan ini menyatakan bahwa skripsi ini merupakan hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 22 Juni 2022



**Intan Indriyani**  
**NPM. 1817031052**

## **RIWAYAT HIDUP**

Penulis dilahirkan di desa Kampung Baru pada tanggal 10 Mei 2000 sebagai anak pertama dari pasangan Bapak Joni Sopyan dan Ibu Nova Lia Wati.

Penulis menempuh pendidikan di Madrasah Ibtidayah Negeri (MIN) 1 Krui pada tahun 2006-2012, Sekolah Menengah Pertama Negeri (SMPN) 2 Krui pada tahun 2012-2015 dan Sekolah Menengah Atas Negeri (SMAN) 1 Krui pada tahun 2015-2018.

Pada tahun 2018 penulis terdaftar sebagai mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung melalui jalur masuk PMPAP. Selama menjadi mahasiswa penulis memiliki pengalaman organisasi diantaranya yaitu menjadi Anggota Bidang Creativity and Financial Support English Society Unila (Eso Unila) tahun 2018-2021, Anggota Bidang Kemuslimahan Rohani Islam (ROIS) FMIPA Universitas Lampung tahun 2018, Anggota Ikatan Mahasiswa Muslim Pesisir Barat (IKAMM PESBAR) tahun 2018 dan Anggota Himpunan Mahasiswa dan Pemuda Pesisir Barat (HMPPB) tahun 2018.



Pada bulan Februari sampai Maret 2021 penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Labuhan Mandi, Kecamatan Way Krui, Kabupaten Pesisir Barat sebagai bentuk pengabdian mahasiswa dan menjalankan Tri Dharma Perguruan Tinggi. Pada bulan Juli sampai Agustus tahun 2021 penulis melaksanakan Kerja Praktek di Badan Pendapatan Daerah (Bappenda) Wilayah I Bandar Lampung Kota Bandar Lampung sebagai bentuk penerapan ilmu yang telah diperoleh selama kuliah.

## KATA INSPIRASI

Untuk jiwa pemilik semangat yang tak pernah padam.

Untuk jiwa pemilik mimpi yang tak pernah habis.

Untuk jiwa pemilik doa yang tak pernah putus.

Tak perlu khawatir akan bagaimana alur cerita pada jalan ini, perankan saja, Tuhan ialah sebaik-baiknya sutradara. Karena yang menjadi takdirmu akan mencari jalannya sendiri untuk menemukanmu.

Memang tidak mudah menjadikan semuanya indah. Ada banyak resah yang harus diubah menjadi tabah. Ada banyak lelah yang tak boleh kalah dengan kata “menyerah”. Tetapi yakinlah, di setiap rasa resah dan lelah akan ada doa baik yang di ijabah.

*No matter how, don't ever get tired of being kind.* Karena kita tidak pernah tau kebaikan mana yang akan membawa kita ke surga-Nya

Tak apa untuk rehat sejenak, lalu lekas mengusahakan. Karena tidak ada ujian yang mudah untuk hidup yang lebih indah. Jangan berfikir buruk apalagi berputus asa, tidak ada yang sulit bagi Allah yang maha kuasa.

Untuk jiwa yang masih bertahan sampai detik ini,

Kisah ini sudah kita mulai dengan “Bismillah”, jangan pernah menyerah sampai akhirnya bisa mengatakan “Alhamduillah”.

(Intan Indriyani)

## **PERSEMBAHAN**

Puji Syukur kepada Allah SWT yang telah memberikan kemudahan dalam menyelesaikan skripsi ini. Dengan segala kerendahan hati, ku persembahkan karya syarat perjuangan kelulusan ku ini kepada,

### **Ayahanda Joni Sopyan dan Ibunda Nova Lia Wati**

Terima kasih telah memberikan kasih sayang yang tulus, tetes keringat pengorbanan, semangat dan motivasi yang tiada henti, doa yang tak pernah terputus, dan sabar yang tak pernah habis untuk menanti keberhasilanku. Atas doa dan ridho kalian, Allah beri kemudahan dalam menjalankan kehidupan ini.

### **Andung, Datuk, Agung, Fadhil, Kautsar dan keluarga**

Yang telah memberi semangat, bantuan serta doa yan tulus untuk selalu berusaha dan berikhtiar kepada Allah SWT.

### **Dosen Pembimbing dan Pembahas**

Yang senantiasa membimbing, mengarahkan dan memberi motivasi sejak awal hingga terselesaikannya skripsi ini.

**Almamater tercinta, Universitas Lampung**

## SANWACANA

Penulis mengucapkan puji syukur kehadirat Allah SWT, karena berkat ridho dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Analisis Struktur Terbaik Algoritma *Artificial Neural Network* untuk Memprediksi Debit Air Bendungan Batu Tegi Menggunakan Metode *Backpropagation*”. Selesaiannya penulisan skripsi ini adalah berkat bimbingan serta motivasi dari berbagai pihak. Dengan segala kerendahan dan ketulusan hati penulis ingin menyampaikan ucapan terima kasih kepada :

1. Ir. Warsono, M.S., Ph.D., selaku pembimbing pertama yang telah memberikan arahan, bimbingan, saran serta motivasi kepada penulis dalam menyelesaikan skripsi ini.
2. Dr. Ir. Slamet Budi yuwono, M.S., selaku pembimbing kedua yang telah memberikan arahan, bimbingan dan saran kepada penulis dalam menyelesaikan skripsi ini.
3. Prof. Drs. Mustofa Usman, M.A., Ph.D., selaku pembahas yang telah memberikan kritik dan saran hingga terselesaikannya skripsi ini.
4. Drs. Eri Setiawan, M.Si., selaku pembimbing akademik yang telah memberikan bimbingan dan motivasi kepada penulis selama menuntut ilmu di Universitas Lampung.
5. Dr. Eng. Suripto Dwi Yuwono, M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Para Dosen dan Staf Jurusan Matematika FMIPA Universitas Lampung.
7. Nenek ku tercinta, tersayang dan terkasih Hj. Maisaroh sosok yang menjadi sayapku yang menjadi motivasiku untuk terbang setinggi bintang.
8. Ayah, Mak, Agung, Dongah Fadhil, Adek Kautsar, Andung Upik, Nda Rika Nda Rosi, Nda Yolana, Uncu Pitra, Nda Emi, Mama Elva, Awan Ari, Awan Sadam,

Nda Hesti, Nabila dan Keluarga tersayang yang selalu memberi semangat, motivasi dan doa yang tak terputus kepada penulis.

9. Sahabatku (Ratu Risha, Sherli, Ranti, Aul, Muflihah) yang telah memberikan kebahagiaan dan keceriaan selama menjalani perkuliahan, yang telah membantu, memberi semangat kepada penulis.
10. Teman-teman jurusan Matematika angkatan 2018 serta keluarga Eso Unila.
11. Semua pihak yang terlibat dalam penyelesaian skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa masih ada kekurangan dalam skripsi ini, akan tetapi besar harapan penulis bahwa skripsi ini dapat bermanfaat bagi penulis maupun pembaca.

Bandar Lampung, 22 Juni 2022  
Penulis

**Intan Indriyani**



## DAFTAR ISI

	Halaman
<b>DAFTAR TABEL</b> .....	xv
<b>DAFTAR GAMBAR</b> .....	xvii
<b>I. PENDAHULUAN</b> .....	1
1.1 Latar Belakang dan Masalah .....	1
1.2 Tujuan Penelitian .....	3
1.3 Manfaat Penelitian .....	3
<b>II. TINJAUAN PUSTAKA</b> .....	4
2.1 Bendungan .....	4
2.2 Debit Air .....	6
2.3 Statistika Deskriptif .....	6
2.4 Analisis Deret Waktu.....	7
2.4.1 Autokorelasi .....	7
2.4.2 Pola Data Deret Waktu .....	10
2.5 Peramalan ( <i>Forecasting</i> ) .....	12
2.6 <i>Statistical Learning</i> .....	13
2.7 Jaringan Syaraf Tiruan ( <i>Artificial Neural Network</i> ) .....	14
2.7.1 Komponen Jaringan Syaraf Tiruan.....	15
2.7.2 Arsitektur Jaringan .....	17
2.7.3 Fungsi Aktivasi.....	19
2.8 <i>Backpropagation</i> .....	21
2.9 Validasi Model .....	22
<b>III. METODOLOGI PENELITIAN</b> .....	24
3.1 Waktu dan Tempat Penelitian .....	24
3.2 Data Penelitian.....	24
3.3 Metode Penelitian .....	24
<b>IV. HASIL DAN PEMBAHASAN</b> .....	29
4.1 Analisis Deskriptif .....	29
4.2 Membangun Jaringan <i>Artificial Neural Network</i> <i>Backpropagation</i> .....	30
4.2.1 Pemeriksaan Data <i>Missing</i> .....	30
4.2.2 Menentukan Input.....	30

4.2.3	Pembagian Data.....	31
4.2.4	<i>Pre-processing</i> Data.....	31
4.2.5	Menentukan Model FFNN <i>Backpropagation</i> yang Optimal .....	32
4.2.6	Denormalisasi.....	34
4.3	Menerapkan dan Membangun Model FFNN <i>Backpropagation</i> Terbaik untuk Melakukan Peramalan Debit Air .....	35
4.3.1	Pemeriksaan Data <i>Missing</i> .....	35
4.3.2	Penentuan <i>Input</i> Jaringan .....	35
4.3.2.1	Variabel <i>Input</i> Curah Hujan, Elevasi Bendung, Luas Genangan, dan Volume Bendung.....	36
4.3.2.2	Variabel <i>Input</i> Curah Hujan .....	36
4.3.2.3	Variabel <i>Input</i> Lag Debit <i>Inflow</i> .....	37
4.3.3	Pembagian Data.....	39
4.3.3.1	Pembagian Data <i>Input</i> Curah Hujan, Elevasi Bendung, Luas Genangan, dan Volume Bendung .....	39
4.3.3.2	Pembagian Data <i>Input</i> Curah Hujan .....	40
4.3.3.3	Pembagian Data <i>Input</i> Lag Debit <i>Inflow</i> .....	40
4.3.4	<i>Pre-processing</i> Data.....	40
4.3.4.1	<i>Pre-processing</i> Data Empat <i>Input</i> .....	41
4.3.4.2	<i>Pre-processing</i> Data <i>Input</i> Curah Hujan .....	41
4.3.4.3	<i>Pre-processing</i> Data <i>Input</i> Lag Debit <i>Inflow</i> ....	42
4.3.5	Penentuan Model FFNN <i>Backpropagation</i> yang Optimal .....	42
4.3.5.1	Model FFNN <i>Backpropagation</i> Empat <i>Input</i> .....	43
4.3.5.2	Model FFNN <i>Backpropagation</i> <i>Input</i> Curah Hujan .....	45
4.3.5.3	Model FFNN <i>Backpropagation</i> <i>Input</i> Lag Debit <i>Inflow</i> .....	47
4.3.6	Denormalisasi.....	51
4.3.7	Akurasi Model.....	52
4.4	Peramalan Debit <i>Inflow</i> Bendungan Batu Tegi .....	52
<b>V.</b>	<b>KESIMPULAN DAN SARAN</b> .....	56
5.1	Kesimpulan.....	56
5.2	Saran.....	57
	<b>DAFTAR PUSTAKA</b> .....	58
	<b>LAMPIRAN</b> .....	62

## DAFTAR TABEL

Tabel	Halaman
1. Simbol-simbol Algoritma <i>Backpropagation</i> .....	27
2. Pemeriksaan Data <i>Missing</i> .....	35
3. Data Input Curah Hujan, Elevasi Bendung, Luas Genangan, dan Volume Bendung .....	36
4. Data <i>Input</i> Curah Hujan .....	37
5. Data <i>Input</i> Lag Debit <i>Inflow</i> .....	39
6. Pembagian Data <i>Training</i> dan <i>Testing</i> Empat <i>Input</i> .....	39
7. Pembagian Data <i>Training</i> dan <i>Testing</i> <i>Input</i> Curah Hujan .....	40
8. Pembagian Data <i>Training</i> dan <i>Testing</i> <i>Input</i> Lag Debit <i>Inflow</i> .....	40
9. Data Empat <i>Input</i> Setelah Normalisasi .....	41
10. Data <i>Input</i> Curah Hujan Setelah Normalisasi .....	41
11. Data <i>Input</i> Lag Debit <i>Inflow</i> Setelah Normalisasi .....	42
12. <i>Multilayer Perceptron</i> dengan Satu Hidden Layer Empat <i>Input</i> .....	43
13. <i>Multilayer Perceptron</i> dengan Dua Hidden Layer dan <i>Threshold</i> 0,01 Empat <i>Input</i> .....	44
14. <i>Multilayer Perceptron</i> dengan Satu Hidden Layer <i>Input</i> Curah Hujan .....	45
15. <i>Multilayer Perceptron</i> dengan Dua Hidden Layer <i>Input</i> Curah Hujan .....	46
16. <i>Multilayer Perceptron</i> dengan <i>Threshold</i> 0,01 .....	47
17. <i>Multilayer Perceptron</i> dengan <i>Threshold</i> 0,001 .....	48

18. Bobot Model Algoritma <i>Backpropagation</i> .....	50
19. Data Input Peramalan Debit <i>Inflow</i> .....	53
20. Hasil Peramalan Debit <i>Inflow</i> 1-5 Januari 2021 .....	55

## DAFTAR GAMBAR

Gambar	Halaman
1. Plot Autokorelasi pada Data <i>Time Series</i> .....	9
2. Pola Data Deret Waktu .....	11
3. Jaringan Layer Tunggal .....	17
4. Jaringan Layer Jamak .....	18
5. Jaringan Layer <i>Reccurant</i> .....	19
6. Fungsi Aktivasi <i>Sigmoid Biner</i> .....	20
7. Fungsi Aktivasi Tanh .....	20
8. Arsitektur Jaringan <i>Backpropagation</i> .....	22
9. <i>Flowchart</i> Sistem Pelatihan dan Pengujian <i>Backpropagation</i> .....	28
10. Plot Data Aktual Debit Inflow 2018-2020.....	29
11. Plot ACF data debit <i>inflow</i> .....	37
12. Plot PACF data debit <i>inflow</i> .....	38
13. Jaringan FFNN Algoritma <i>Backpropagation</i> Fungsi Aktivasi Sigmoid dengan Dua <i>Hidden Layer</i> dengan Empat <i>Input</i> .....	45
14. Jaringan FFNN Algoritma <i>Backpropagation</i> Fungsi Aktivasi Sigmoid dengan Dua <i>Hidden Layer</i> dengan <i>Input</i> Curah Hujan .....	47
15. Jaringan FFNN Algoritma <i>Backpropagation</i> Fungsi Aktivasi Sigmoid dengan Dua <i>Hidden Layer</i> dengan <i>Input</i> Lag Debit <i>Inflow</i> .....	49
16. Plot Perbandingan Data Prediksi dengan Data Aktual dari Proses Denormalisasi. ....	52



## I. PENDAHULUAN

### 1.1 Latar Belakang dan Masalah

Bendungan merupakan salah satu sumber daya yang memiliki peran penting dalam berbagai sektor kehidupan seperti halnya Bendungan Batu Tegi. Bendungan ini terletak di desa Batu Tegi, kecamatan Air Naningan, kabupaten Tanggamus, provinsi Lampung. Peresmian pengoperasian Bendungan Batu Tegi pada tanggal 8 Maret 2004 oleh Presiden RI Megawati Soekarnoputri (Amran, 2012). Pembangunan Bendungan Batu Tegi merupakan alternatif bagi pengembangan irigasi Way Sekampung, disamping fungsi lain yaitu sebagai sumber energi Pembangkit Listrik Tenaga Air (PLTA) dengan kapasitas terpasang 2 x 14 MW, air baku, pariwisata, pengendalian banjir dan perikanan (Amran, 2012). Bendungan Batu Tegi berada dibagian hulu DAS Way Sekampung dengan luas daerah tangkapan hujan (*catchment area*) sebesar 424 km<sup>2</sup> sebagai sumber utama air irigasi 108.553 ha sawah (Ridwan dkk., 2013). Adanya fungsi yang kompleks dari bendungan, maka kesalahan dalam pengoperasian Bendungan Batu Tegi tentunya tidak diharapkan, kekurangan ataupun kelebihan tampungan air (*storage*) dan kesalahan saat akan pelepasanan air (*release*) dapat merugikan. Terjadinya banjir karena debit yang berlebihan bisa terjadi, atau *storage* yang tidak mencukupi dapat mengakibatkan *suply* untuk irigasi dan pengoperasian pembangkit listrik berkurang. Hal ini menyebabkan jumlah produksi pertanian dan produksi energi menurun.

Besarnya debit *outflow* dari bendungan untuk didistribusikan dipengaruhi oleh besarnya debit *inflow* bendungan. Besar nya debit *inflow* itu sendiri dipengaruhi oleh dua faktor yaitu faktor meteorologi (intensitas hujan, durasi hujan, distribusi curah hujan) dan faktor karakteristik DAS (luas dan bentuk lahan, topografi, tata guna lahan) (Susilowati, 2007). Menurut Supriyadi, Banuwa, & Yuwono (2018) Total *inflow* bulanan cenderung berfluktuasi berdasarkan fluktuasi curah hujan. Data mengenai besarnya *inflow* dimasa lalu merupakan satu-satunya informasi yang tersedia untuk memperkirakan *inflow* dimasa yang akan datang. Menurut Ridwan dkk. (2013) setelah tahap operasional sejak tahun 2004 hingga tahun 2013 kondisi elevasi Bendungan Batu Tegi belum pernah mencapai elevasi normal (+274 m) diduga karena semakin menurunnya debit *inflow* dan semakin meningkatnya debit *outflow* untuk memenuhi permintaan air irigasi Bendungan Argoguruh. Dengan demikian, berdasarkan kajian tersebut dapat disimpulkan bahwa pengoperasian bendungan belum optimal. Kondisi terbaik dari pengoperasian bendungan bisa dicapai jika analisisnya mempertimbangkan persediaan air dan pelepasan air (Elmasari & Nurhadi, 2019). Berdasarkan besar *inflow* yang masuk, maka dapat diatur seberapa pelepasan air dan persediaan air Bendungan Batu Tegi dapat dipertahankan di level yang seharusnya. Pengeluaran (*outflow*) air harus dilakukan sedemikian rupa sehingga *storage* Bendungan Batu Tegi setiap saat dapat mendekati pedoman pengoperasian yang ada.

Pada kajian ini akan digunakan teknik kecerdasan buatan menggunakan Jaringan Syaraf Tiruan (JST). Jaringan Syaraf Tiruan atau yang bisa dikenal dengan istilah *Artificial Neural Network* (ANN) metode ini merupakan salah satu bagian dari *machine learning*. Salah satu model Jaringan Syaraf Tiruan adalah *Feedforward Neural Network* (FFNN), dimana siklus pelatihan berjalan dari lapisan masukan ke lapisan hasil berikutnya. Tujuan penelitian ini adalah menentukan struktur terbaik dari algoritma FFNN *Backpropagation* untuk dapat meramalkan debit *inflow* dimasa yang akan datang sehingga dapat digunakan sebagai input dalam manajemen pengoperasian dan optimasi terhadap pemakaian air di Bendungan Batu Tegi. Penggunaan Jaringan Syaraf Tiruan untuk analisis data *time series* telah banyak dilakukan, antara lain Rezaei dkk., (2015) menggunakan algoritma

*backpropagation* untuk meramalkan aliran sungai Shoor Ghaen. Xu & Li (2002) menggunakan algoritma *backpropagation neural network* untuk meramalkan debit *inflow* jangka pendek. Herawati, Suripin & Suharyanto (2017). menggunakan algoritma *backpropagation* untuk memodelkan aliran sungai Kapuas, Kalimantan Barat Indonesia. Chiamsathit dkk., (2016) meramalkan *inflow* menggunakan ANN untuk operasi waduk. Shamseldin (2010) menggunakan jaringan syaraf tiruan untuk meramalkan aliran sungai di negara berkembang.

## 1.2 Tujuan Penelitian

Sesuai dengan pokok permasalahan yang telah diambil, maka adapun tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Menjelaskan prosedur dalam pembentukan model FFNN *Backpropagation* pada data yang berbentuk *time series*.
2. Menentukan fungsi aktivasi terbaik untuk meramalkan debit *inflow* berdasarkan tingkat akurasi model.
3. Untuk mendapatkan arsitektur FFNN *Backpropagation* yang terbaik digunakan data set yang tersedia untuk meramalkan debit *inflow* Bendungan Batu Tegi.

## 1.3 Manfaat Penelitian

Manfaat yang diambil dari penelitian yang penulis tulis ini adalah:

1. Sebagai bahan referensi atau acuan dalam mengaplikasikan Algoritma *Backpropagation Neural Network* untuk peramalan di masa yang akan datang.
2. Sebagai bahan pertimbangan di masa akan datang untuk memanfaatkan semaksimal mungkin debit *inflow* bendungan batu tegi yang ada dan dengan sebijak mungkin memanfaatkan air untuk irigasi.

## II. TINJAUAN PUSTAKA

### 2.1 Bendungan

Bendungan merupakan salah satu bentuk bangunan air yang dibuat secara melintang sungai, sedemikian rupa agar permukaan air sungai di sekitarnya naik sampai ketinggian tertentu, sehingga air sungai dapat dialirkan melalui pintu sadap ke saluran-saluran pembagi kemudian hingga ke lahan-lahan pertanian (Kartasapoetra & Sutedjo, 1991). Bendungan mempunyai bermacam-macam jenis, antara lain (Sarono & Asmoro, 2007):

1. Jenis bendungan berdasarkan tujuan pembangunannya:
  - a. Bendungan dengan tujuan tunggal (*single purpose dam*) ialah bendungan yang dibangun hanya untuk satu tujuan.
  - b. Bendungan serbaguna (*multipurpose dam*) adalah bendungan yang dibangun untuk beberapa tujuan.
2. Jenis bendungan berdasarkan penggunaannya:
  - a. Bendungan penampung air (*storage dam*) adalah bendungan yang digunakan untuk menyimpan air berlebih dan digunakan pada saat kekurangan, yang termasuk dalam bendungan penampung air adalah perikanan, tujuan rekreasi, pengendalian banjir, dan lain-lain.
  - b. Bendungan pembelok (*diversion dam*) adalah bendungan yang digunakan untuk menaikkan ketinggian air.
  - c. Bendungan penahan (*detention dam*) adalah bendungan yang digunakan untuk memperlambat dan mencoba meminimalkan efek banjir yang mendadak.

3. Tipe bendungan berdasarkan jalannya air:
  - a. Bendungan untuk mengalirkan air (*overflow dam*) adalah bendungan yang dibuat untuk dilimpasi air di pelimpah (*spillway*).
  - b. Bendungan untuk menahan air (*non overflow dam*) adalah bendungan yang tidak boleh dilimpasi air sama sekali.
4. Tipe bendungan berdasarkan bahan pembentuknya:
  - a. Bendungan urugan (*rock fill dam, embankment dam*) adalah bendungan yang dibuat dari bahan galian (material) tanpa bahan campuran kimia lainnya.
  - b. Bendungan beton (*concrete dam*) adalah bendungan yang terbuat dari konstruksi beton dengan atau tanpa tulangan.

Beberapa fungsi dari bendungan atau waduk antara lain (Sarono & Asmoro, 2007):

1. Irigasi  
Pada saat musim hujan, air hujan yang turun di daerah tangkapan air sebagian besar akan ditampung sehingga pada musim kemarau air yang tertampung tersebut dapat dimanfaatkan untuk berbagai keperluan, antara lain sebagai irigasi lahan pertanian.
2. Penyediaan Air Baku  
Bendungan selain berfungsi sebagai sumber irigasi juga dimanfaatkan sebagai bahan baku air minum.
3. Sebagai PLTA  
Pembangkit listrik tenaga air (PLTA) adalah suatu sistem pembangkit listrik yang biasanya terintegrasi dalam bendungan dengan memanfaatkan energi mekanis aliran air untuk memutar turbin, diubah menjadi energi listrik melalui generator.
4. Pengendali Banjir  
Dengan dibangunnya bendungan-bendungan di bagian hulu sungai maka kemungkinan terjadinya banjir pada musim hujan dapat dikurangi dan pada musim kemarau air yang tertampung tersebut dapat dimanfaatkan untuk berbagai keperluan.



## 5. Perikanan

Untuk mata pencaharian warga dengan memanfaatkan waduk untuk budidaya di jaring apung atau karamba.

## 6. Pariwisata dan Olahraga Air

Dengan pemandangan yang indah bendungan juga bisa digunakan sebagai tempat rekreasi dan selain itu juga digunakan sebagai tempat olahraga air sekaligus tempat latihan para atlet olahraga air.

## 2.2 Debit Air

Debit merupakan laju aliran air (dalam bentuk volume air) yang melewati segmen melintang saluran air per satuan waktu. Besaran debit dalam sistem Satuan Internasional SI dinyatakan sebagai satuan meter kubik per detik ( $\text{m}^3/\text{dt}$ ). Dalam laporan khusus, debit aliran ditampilkan dalam bentuk hidrograf aliran. Hidrograf aliran adalah perilaku debit dalam menanggapi perubahan karakteristik biogeofisik yang terjadi di pada suatu DAS (oleh adanya kegiatan pengelolaan DAS) atau perubahan (fluktuasi musiman atau tahunan) iklim lokal (Asdak, 2001).

## 2.3 Statistika Deskriptif

Statistika deskriptif berfungsi untuk memberikan gambaran terhadap objek yang diteliti melalui data sampel atau populasi (Sugiyono, 2007). Data yang disajikan dalam statistik deskriptif biasanya berupa ukuran pemusatan data (Kuswanto, 2012). *Mean* (rata-rata), nilai maksimum, dan minimum adalah ukuran pemusatan data yang biasa digunakan untuk mendeskripsikan kumpulan data. Nilai rata-rata (*Mean*) atau nilai tengah merupakan suatu ukuran pemusatan data jika data diurutkan dari yang terkecil ke terbesar atau sebaliknya untuk mengukur nilai rata-rata data.

*Varians* sampel ( $S^2$ ) adalah ukuran penyebaran data yang mengukur rata-rata kuadrat jarak antara semua titik pengamatan dari nilai tengah. Nilai maksimum itu sendiri merupakan nilai observasi tertinggi dari sekumpulan data sedangkan, nilai minimum merupakan nilai terendah dari sekumpulan data.

Penelitian deskriptif adalah metode penelitian yang digunakan untuk menemukan pengetahuan yang luas tentang objek penelitian pada waktu tertentu. Kumpulan data yang di dapatkan oleh statistika deskriptif selalu tersaji dengan singkat dan rapi serta memberikan informasi utama dari kesimpulan data. Informasi yang didapatkan dari statistika deskriptif yaitu ukuran pemusatan data, ukuran penyebaran data, dan kecendrungan sekumpulan data (Walpole, *et al.*, 2011).

## 2.4 Analisis Deret Waktu

Deret waktu (*time series*) adalah pengamatan pada suatu variabel dari waktu lampau atau masa lalu yang dicatat sesuai dengan urutan waktu dan periode yang tetap (Hanke dan Wichern, 2014). Pada dasarnya pencatatan dilakukan dalam periode tertentu antara lain: harian, bulanan, tahunan dan sebagainya. Sedangkan analisis deret waktu merupakan suatu metode kuantitatif yang digunakan untuk menentukan pola data masa lalu atau lampau yang telah dikumpulkan secara berurutan dan teratur. Jika pola data tersebut telah ditemukan, maka pola tersebut dapat digunakan untuk peramalan di masa mendatang.

### 2.4.1 Autokorelasi

Autokorelasi merupakan suatu korelasi pada data *time series* antara  $X_t$  dengan  $X_{t+k}$ . Untuk mendefinisikan autokorelasi diperlukan definisi autokovarians. Autokovarians dan autokorelasi antara  $X_t$  dan  $X_{t+k}$  berturut-turut dapat didefinisikan sebagai berikut (Wei, 2006):

$$\gamma_k = Cov(X_t, X_{t+k}) = E[(X_t - \mu)(X_{t+k} - \mu)] \quad (2.1)$$

dan

$$\rho_k = r_k \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)}\sqrt{Var(X_{t+k})}} \frac{\gamma_k}{\gamma_0} \quad (2.2)$$

dengan:

$X_t$  = pengamatan pada waktu ke-t

$X_{t+k}$  = pengamatan pada waktu ke-t+k

Dimana  $(X_t) = (X_{t+k}) = \gamma_0$  dan  $\rho_0 = 1$ . Sebagai fungsi dari k,  $\gamma_k$  disebut fungsi autokovarians dan  $\rho_k$  disebut sebagai fungsi autokorelasi (*autocorrelation function*) atau ACF, yang mewakili kovarians dan korelasi antara  $X_t$  dan  $X_{t+k}$  dari proses yang sama, hanya dipisahkan oleh *time lag*-k. Jika  $X_t$  dan  $X_{t+k}$  independen maka  $\gamma_k = (X_t, X_{t+k}) = 0$  tetapi tidak berlaku sebaliknya.  $X_t$  dan  $X_{t+k}$  dikatakan tidak berkorelasi jika  $\rho_k = 0$ . Dua variabel dengan hubungan negatif sempurna memiliki koefisien korelasi sebesar -1. Di lain kasus, dua variabel dengan hubungan positif sempurna memiliki koefisien korelasi sebesar +1. Dengan demikian, koefisien korelasi bervariasi antara -1 dan +1 (Hanke dan Wichern, 2014).

Hipotesis untuk menguji signifikansi autokorelasi dirumuskan sebagai:

$H_0 : \rho_k = 0$  (autokorelasi pada lag ke-k tidak signifikan)

$H_0 : \rho_k \neq 0$  (autokorelasi pada lag ke-k signifikan)

Uji signifikan menggunakan distribusi t, dengan statistik uji:

$$t = \frac{r_k}{SE(r_k)} \quad (2.3)$$

Standar *error* dari koefisien autokorelasi menggunakan rumus sebagai berikut (Hanke dan Wichern, 2014):

$$SE(r_k) = \sqrt{\frac{1 + 2 \sum_{l=1}^{k-1} r_l^2}{n}} \quad (2.4)$$

dengan:

$(r_k)$  = standar *error* koefisien korelasi pada lag k

$r_k$  = koefisien korelasi pada lag k

$n$  = banyaknya pengamatan

Koefisien autokorelasi pada lag k dikatakan signifikan jika  $t_{hitung} > t_{(n-1)}\left(\frac{\alpha}{2}\right)$  atau

$t_{hitung} < t_{(n-1)}\left(\frac{\alpha}{2}\right)$  dan ketika menggunakan nilai Sig. maka koefisien autokorelasi

pada lag k dikatakan signifikan jika Sig.  $< \left(\frac{\alpha}{2}\right)$ . Signifikan koefisien autokorelasi

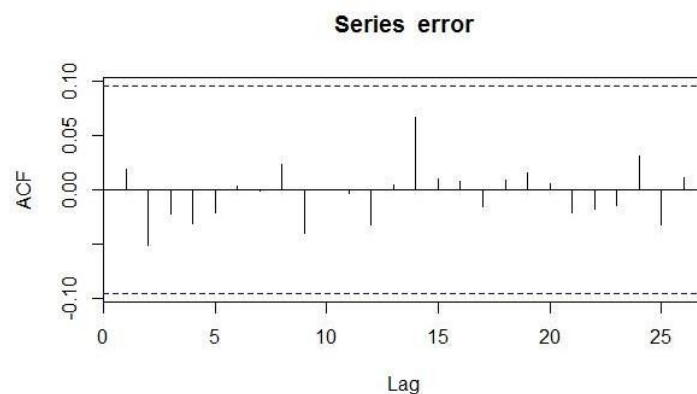
juga dapat dilihat dari selang kepercayaan dengan pusat  $r_k = 0$  yang jika dilihat

dari tampilan plot fungsi berupa garis putus-putus berwarna merah. Interval

kepercayaan ditemukan dengan cara menghitung:

$$0 \pm t_{(n-1)}\left(\frac{\alpha}{2}\right) \times SE(r_k) \quad (2.5)$$

Pada gambar 1 menunjukkan plot autokorelasi pada deret waktu dimana garis yang keluar dari batas signifikan menunjukkan adanya autokorelasi signifikan.



Gambar 1. Plot autokorelasi pada data deret waktu.

Autokorelasi parsial digunakan untuk mengukur derajat keeratan antara  $X_t$  dan  $X_{t-k}$ , apabila pengaruh dari *time* lag 1, 2, 3, ..., dan seterusnya sampai k-1 dihapus. Autokorelasi parsial ditentukan dengan rumus berikut:

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}} \quad (2.6)$$

Dengan  $\phi_{kk}$  adalah autokorelasi parsial antara  $X_t$  dan  $X_{t+k}$ , karena merupakan fungsi dari  $k$ , himpunan  $\{\phi; k = 0, 1, 2, \dots\}$  dinamakan fungsi autokorelasi parsial (*partial autocorrelation function*), disingkat dengan PACF (Wei, 2006).

#### 2.4.2 Pola Data Deret Waktu

Langkah utama dalam menentukan metode peramalan deret waktu ialah jenis pola data, karena dengan mengetahui jenis pola maka data tersebut dapat menentukan metode peramalan yang paling tepat untuk diuji. Berikut merupakan komponen yang mempengaruhi analisis yaitu:

##### 1. Pola Siklis (*Cycle*)

Karakter yang dimiliki pola siklis yaitu dari pergerakan seperti gelombang yang lebih panjang dari pada satu tahun dan tidak pasti berulang pada interval waktu yang sama. Sedangkan karakteristik dari pola musiman dimana terjadi pengulangan pola secara konsisten. Bentuk pola siklis adalah berulang antar waktu kejadian secara periodik. Komponen pola siklis bermanfaat untuk peramalan data dalam jangka menengah.

##### 2. Pola musiman (*Seasonal*)

Dikatakan pola musiman jika data setiap periode membentuk pola yang berulang atau sama secara periodik dan bergerak secara bebas. Karakter pola musiman ialah dimana puncak dan lembah berulang dalam periode yang konsisten. Negara yang mengalami pergantian cuaca sebanyak 4 kali yaitu musim semi (*spring*), musim panas (*summer*), musim gugur (*fall*) dan musim dingin (*winter*) merupakan contoh pola musiman.



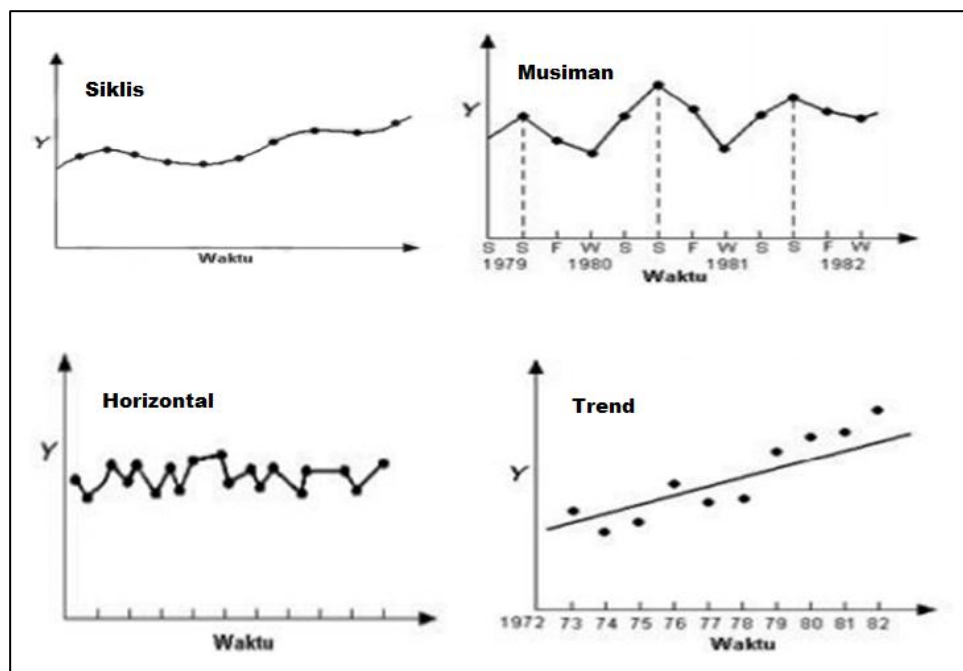
3. Pola Horizontal

Pola horizontal terjadi saat *mean* yang konstan terdapat nilai yang berfluktuasi. Dikatakan fluktuasi saat data naik dan turun tergantung pada kondisi data antar data satu dengan yang lainnya.

4. Pola *Trend*

Dikatakan pola *trend* yang mengalami naik atau turun menerus sampai waktu (t) tertentu. Penjualan mobil dan berbagai indikator bisnis serta ekonomi lainnya dengan suatu pola *trend* selama pembahasannya sepanjang waktu merupakan contoh dari pola *trend*.

Menurut Makridakis, Wheelwright, & McGee (1999), pada gambar berikut menjelaskan keempat pola tersebut.



Gambar 2. Pola Data Deret Waktu

## 2.5 Peramalan (*Forecasting*)

Peramalan (*forecasting*) adalah perkiraan dari nilai atau kondisi di masa yang akan datang atau masa depan. Asumsi umum yang dipakai dalam peramalan adalah pola masa lampau akan berlanjut ke yang akan datang.. Meramal juga didasarkan pada keahlian penilaian, yang pada gilirannya didasarkan pada data historis dan pengalaman (Makridakis dkk., 1999).

Menurut Heizer & Render (2006), peramalan berdasarkan horizontal waktu dicakup diklasifikasikan menjadi 3 kategori, antara lain :

1. Peramalan jangka pendek, mencakup jangka waktu 12 bulan biasanya kurang dari tiga bulan.
2. Peramalan jangka menengah, peramalan ini biasanya mencakup waktu tiga bulan hingga tiga tahun.
3. Peramalan jangka panjang peramalan ini biasanya untuk perencanaan tiga tahun atau lebih.

Menurut Makridakis dkk. (1999), ada dua kategori utama metode peramalan, yaitu metode kualitatif dan kuantitatif. Metode peramalan kualitatif digunakan saat data masa lalu tidak tersedia maka dari itu peramalan tidak bisa dilakukan. Yang menjadi pertimbangan dalam pengambilan keputusan sebagai hasil dari peramalan yang telah dilakukan pada metode kualitatif adalah pendapat-pendapat para ahli. Namun, jika data masa lalu tersedia, maka peramalan akan lebih efektif saat menggunakan metode kuantitatif. Tujuan metode kuantitatif adalah mempelajari hal yang telah terjadi di masa lalu untuk meramalkan nilai di waktu yang akan datang. Peramalan menggunakan metode kuantitatif dibagi menjadi dua bagian, yaitu (Santoso, 2009):

1. Metode peramalan berdasarkan penggunaan analisa pola hubungan antara variabel yang akan diperiksa dengan variabel waktu, yang merupakan deret waktu.

2. Metode peramalan berdasarkan pada penggunaan analisis pola hubungan antar variabel yang akan diestimasi dengan variabel lain yang mempengaruhi, bukan waktu, disebut metode korelasi atau sebab akibat (*causal methods*).

## 2.6 *Statistical Learning*

Sama sekali tidak seperti model alami atau biologis, ANN mempunyai struktur yang tidak berubah, bekerja dan dibangun oleh *neuron-neuron*, serta memiliki nilai tertentu yang menunjukkan berapa besar hubungan antara *neuron* (dikenal sebagai nama bobot). Perubahan yang terjadi saat proses *training* adalah perubahan nilai bobot. Nilai bobot bertambah, jika asumsi data yang diberikan oleh *neuron* yang dirujuk diteruskan, sebaliknya jika asumsi tidak diteruskan oleh *neuron* ke *neuron* yang lain, maka pada saat itu nilai bobot yang menghubungkan keduanya akan berkurang. Selama pembelajaran dilakukan pada *input* yang berbeda, maka nilai bobot akan diubah secara bertahap hingga mencapai nilai yang sesuai dan seimbang. Disaat nilai tersebut telah tercapai menunjukkan bahwa setiap *input* terhubung dengan hasil *output* yang diharapkan (Kristanto, 2004).

*Statistical Learning* adalah kerangka kerja yang menggambarkan pembelajaran mesin dari bidang statistik dan analisis fungsional untuk pemodelan dan pemahaman kumpulan data kompleks (James dkk., 2013). *Statistical Learning* adalah bidang yang baru-baru ini dikembangkan dalam statistik dan perkembangan ilmu komputer, khususnya *machine learning*. Bidang ini mencakup banyak metode seperti *lasso* dan *sparse regression*, *classification* dan *regression trees*, serta *boosting* dan *support vector machines*.

*Statistical Learning* mengacu pada seperangkat alat yang luas untuk memahami data. Alat tersebut yang dapat diklasifikasikan menjadi dua kategori, yaitu *supervised learning* dan *unsupervised learning*.

a. Pelatihan Terawasi (*Supervised Learning*)

*Supervised learning* dilakukan dengan adanya urutan vektor pelatihan, atau pola yang masing-masing dikaitkan dengan vektor target keluaran. Bobot kemudian disesuaikan untuk algoritma pembelajaran. Pada umumnya *supervised learning* melibatkan pembangunan model statistik untuk memperkirakan keluaran berdasarkan satu atau lebih masukan.

b. Pelatihan tak Terawasi (*Unsupervised Learning*)

Pada *unsupervised learning* jaringan saraf mengatur seluruh kinerjanya, mulai dari masukan vektor sampai menggunakan data *training* untuk melakukan pembelajaran pada data.

Dari perspektif teori pembelajaran statistik, *supervised learning* paling baik dipahami. *Supervised learning* melibatkan pembelajaran dari kumpulan data pelatihan. Setiap poin dalam pelatihan merupakan pasangan *input-output*, dimana *input* dipetakan ke *output*, sehingga fungsi yang dipelajari dapat digunakan untuk memprediksi *output* dari *input* yang akan datang.

Salah satu algoritma *supervised learning* yang populer adalah *artificial neural network*, yaitu sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi (Siang, 2009). Dalam pemrosesan *artificial neural network* terdapat pembagian data menjadi dua, yaitu data training dan data testing. Data *training* dipakai untuk melatih algoritma, sedangkan data testing dipakai untuk mendapatkan performa algoritma yang telah dilatih sebelumnya saat menemukan data baru yang tidak ada sebelumnya. Ini umumnya disebut dengan generalisasi. Hasil pelatihan ini umumnya disebut model.

## 2.7 Jaringan Syaraf Tiruan (*Artificial Neural Network*)

Jaringan Syaraf Tiruan (JST) atau yang bisa dikenal dengan istilah *Artificial Neural Network* (ANN) merupakan salah satu bagian dari *machine learning*. Jaringan syaraf tiruan memiliki kemiripan dengan kondisi otak manusia yang

terbentuk dari sebagian besar *neuron* yang memiliki hubungan sangat erat antara *neuron* satu dengan yang lain (Siang, 2009).

*Artificial Neural Network* telah diterapkan di berbagai bidang seperti *pattern recognition*, *medical diagnostic*, *signal processing*, dan peramalan. Terlepas dari kenyataan bahwa ada banyak aplikasi menjanjikan yang dihasilkan oleh *Artificial Neural Network*, namun *Artificial Neural Network* memiliki beberapa kendala, diantaranya kesalahan hasil yang didapatkan. *Artificial Neural Network* bekerja sesuai dengan pola yang terbentuk dalam *inputnya*.

*Artificial Neural Network* terdiri dari elemen untuk pemrosesan informasi yang disebut dengan *neuron*, unit, sel atau *node* (Khashei, 2010). Setiap *neuron* diasosiasikan dengan *neuron* yang berbeda oleh suatu *connection link*, yang dijelaskan kembali dengan *weight*. Teknik menetapkan harga atau nilai *weight* disebut dengan *learning*, *training*, atau algoritma. Setiap *neuron* menggunakan fungsi aktivasi pada net masukan untuk menentukan hasil prediksi.

### **2.7.1 Komponen Jaringan Syaraf Tiruan**

*Neuron-neuron* dalam *Artificial Neural Network* disusun dalam kelompok-kelompok yang disebut dengan *layer* (lapisan). Arsitektur jaringan merupakan urutan setiap *neuron* dalam lapisan dan pola hubungan di dalam dan antarlapis. Arsitektur ini adalah salah satu karakter utama yang membedakan *neural network*.

awalnya *Artificial Neural Network* hanya memiliki 2 lapisan saja, yaitu *input layer* dan *output layer*. Seiring waktu, jaringan syaraf tiruan dikembangkan bertambahlah 1 lapisan lagi yaitu *hidden layer* yang letaknya antara *input* dan *output layer* (Hermawan, 2006). Lapisan dalam jaringan syaraf tiruan dapat dibagi menjadi 3 bagian antara lain:

a. Lapisan *Input (Input Layer)*

Terdapat *neuron* yang memiliki nilai *input* masing-masing. Banyaknya masukan pada pola tergantung dari banyaknya *neuron*. Masukan dari lapisan ini menggambarkan suatu masalah.

b. Lapisan Tersembunyi (*Hidden Layer*)

Semua proses pada fase pelatihan dan fase pengenalan dijalankan didalam lapisan ini. Umumnya hanya terdiri dari satu hidden layer namun tergantung dari arsitektur yang akan dirancang. Lapisan yang menghubungkan antara *input layer* dan *output layer* juga disebut *hidden layer*.

Menurut Huang (2003), pada kasus dua hidden layer dengan  $m$  *neuron output* dan  $N$  sampel, jumlah *hidden layer* pada lapis pertama dirumuskan sebagai:

$$\sqrt{(m + 2)N} + 2\sqrt{\frac{N}{m+2}}, \quad (2.7)$$

dan untuk lapis kedua dirumuskan sebagai:

$$m\sqrt{\frac{N}{m+2}}, \quad (2.8)$$

Menurut Jeff Heaton (2008), jumlah node pada *hidden layer* adalah:

- a. antara jumlah node *input layer* dan *output layer*
- b.  $2/3$  dari jumlah *input layer* ditambah dengan *output layer*
- c. Kurang dari  $2x$  *input layer*

c. Lapisan Keluaran (*Output Layer*)


Nilai keluaran dari hasil perhitungan keseluruhan. Hasil keluaran yang dihasilkan merupakan *output JST* dari suatu permasalahan.

## 2.7.2 Arsitektur Jaringan

Terdapat 3 jenis model arsitektur jaringan syaraf tiruan yaitu:

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

Pada jaringan layar tunggal, sekumpulan *neuron input* dihubungkan dengan *output*. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui lapisan *hidden*. Gambar Jaringan Layer Tunggal (Puspitaningrum, 2006).



Gambar 3. Jaringan Layer Tunggal

dengan:


$$X_1, X_i, X_n = \text{input}$$

$$Y_1, Y_j, Y_m = \text{output}$$

$$W_{11} \dots W_{nm} = \text{matriks bobot}$$

### 2. Jaringan Layak Jamak (*Multi Layer Network*)

Lapisan yang lebih dari satu terletak di antara lapisan *input* dan *output* (terdiri dari 1 atau lebih *hidden layer*). Dengan menggunakan jaringan *layer* jamak masalah yang kompleks dapat mudah terselesaikan dibandingkan jika memakai *layer* tunggal, meskipun proses pelatihannya kadang lebih lama. Menurut Puspitaningrum (2006), berikut susunan Jaringan Layer Jamak.



Gambar 4. Jaringan Layer Jamak

dengan:

$X_1, X_i, X_n = input$

$Z_1, Z_j, Z_p = hidden layer$

$Y_1, Y_k, Y_m = output$


$V_i, \dots = matriks bobot pertama$

$W_i, \dots = matriks bobot kedua$

### 3. Jaringan *Reccurent*

Umumnya, hubungan antara *neuron* pada lapisan kompetitif ini tidak diperlihatkan pada diagram arsitektur. Jaringan *reccurent* sama seperti layar tunggal ataupun ganda. Hanya aja ada *neuron output* yang memberikan sinyal pada *unit input* (sering disebut *feedback loop*). Artinya, sinyal mengalir dua arah, yaitu maju dan mundur. Pada lapisan ini jaringan mempunyai minimal satu *feedback loop* yang terdiri dari masing-masing *neuron* untuk memberikan kembali *output* nya sebagai *input* pada *neuron* lain. Nilai bobot untuk tiap *neuron* adalah 1 dan bobot acak negatif dengan  $-\epsilon$  untuk *neuron* lain. Berikut merupakan struktur jaringan- jaringan dengan lapisan kompetitif. Menurut Puspitaningrum (2006), berikut susunan Jaringan *Reccurent*.





Gambar 5. Jaringan Layer *Reccurent*

dengan:

$A, A_1, A_i, A_j = \text{input}$

$-\epsilon = \text{bobot acak negatif}$

### 2.7.3 Fungsi Aktivasi

Pada JST terdapat fungsi aktivasi yang digunakan untuk menentukan *output* dengan berargumen net *input*. Net *input* terdiri dari kombinasi linier *input* beserta bobotnya (Siang, 2009). Fungsi aktivasi memiliki tujuan untuk memodifikasi *output* kedalam rentang nilai tertentu. Berikut ini adalah fungsi aktivasi yang sering digunakan dalam jaringan syaraf (Kusumadewi, 2003) yaitu:

#### 1. Fungsi *sigmoid biner*


Fungsi *sigmoid biner* memiliki interval *output* 0 sampai 1 dengan membentuk kurva S yang dapat menghasilkan *output* lebih cepat. Fungsi *sigmoid biner* dapat dirumuskan seperti Persamaan 1 dan bentuk dari fungsi *sigmoid biner* digambarkan pada Gambar 6 (Kusumadewi, 2003).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.9)$$

dengan:

$f(x)$  = fungsi aktivasi *sigmoid biner*

$e^{-x}$  = eksponensial pangkat minus data ke-  $x$

Gambar 6. Fungsi Aktivasi *Sigmoid Biner*

## 2. Fungsi Tanh

Fungsi tangen hiperbolik berhubungan erat dengan fungsi *sigmoid bipolar* yang juga sering digunakan sebagai fungsi aktivasi ketika jangkauan yang diharapkan dari nilai output diantara  $-1$  dan  $1$ . Persamaan fungsi Tanh adalah:


$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.10)$$

dengan:

$f(x)$  = fungsi aktivasi *sigmoid bipolar*

$e^{-x}$  = eksponensial pangkat minus data ke-  $x$

$e^x$  = eksponensial pangkat minus data ke-  $x$




Gambar 7. Fungsi Aktivasi Tanh

## 2.8 *Backpropagation*

Seperti yang dijelaskan bahwa ANN mirip seperti otak manusia dalam dua keadaan, salah satunya adalah bahwa informasi diperoleh jaringan melalui sistem pembelajaran. ANN akan berusaha mensimulasikan kemampuan otak manusia untuk belajar. *Artificial neural network* juga tersusun atas *neuron-neuron* dan *dendrit*. Lain halnya dengan model biologis, ANN memiliki struktur yang tidak dapat berubah dan diubah, dibangun oleh *neuron-neuron*, serta memiliki nilai tetap yang menunjukkan besar hubungan atau koneksi antara *neuron* (bobot). Perubahan yang terjadi selama sistem pembelajaran adalah perubahan harga atau nilai bobot. Nilai bobot akan bertambah, jika informasi yang diberikan oleh *neuron* yang bersangkutan tersampaikan, sebaliknya jika informasi tidak disampaikan oleh *neuron* ke *neuron* yang lain, maka nilai bobot yang menghubungkan keduanya akan dikurangi. Saat proses pembelajaran terjadi pada *input* yang lain, saat itu nilai bobot akan diubah secara berurutan hingga mencapai nilai yang sebanding. Apabila nilai ini telah tercapai mengindikasikan bahwa tiap-tiap *input* telah berhubungan dengan *output* yang diharapkan (Kristanto, 2004).

*Backpropagation* atau propagasi balik merupakan suatu teknik pembelajaran atau pelatihan *supervised learning* yang paling banyak digunakan. Metode *Backpropagation* umumnya merupakan teknik yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks. Di dalam jaringannya, setiap unit yang berada di lapisan *input* dikaitkan dengan setiap unit di lapisan *output*. Jaringan ini diisi oleh banyak lapisan. Setiap kali jaringan diberikan desain masukan sebagai pola pelatihan, akan menjalankan pola tersebut menuju unit-unit lapisan tersembunyi lalu diteruskan pada unit-unit di lapisan keluaran. Kemudian unit-unit lapisan keluaran akan memberikan respon sebagai keluaran *artificial neural network*. Saat hasil keluaran tidak sesuai dengan yang diharapkan, maka keluaran akan disebarkan mundur pada lapisan tersembunyi kemudian dari lapisan tersembunyi menuju lapisan masukan (Puspitaningrum, 2006).

Algoritma *Backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur. Untuk mendapat *error* ini, tahap perambatan maju harus dikerjakan terlebih dahulu. Pada saat perambatan maju, *neuron* dari setiap lapisan diaktifkan menggunakan fungsi aktivasi.



Gambar 8. Arsitektur Jaringan *Backpropagation*

Model algoritma *Backpropagation* secara sistematis dapat dituliskan sebagai berikut (Siang, 2009):

$$y_k = \sum_{j=1}^p w_{kj} \cdot f \left[ v_{jo} + \sum_{i=1}^n x_i v_{ji} \right] + w_{ko} \quad (2.11)$$

## 2.9 Validasi Model

Menurut Hanke & Wichern (2014), teknik peramalan yang menggunakan data kuantitatif dengan data runtun waktu tertentu., terdapat *error*/kesalahan yang dihasilkan oleh teknik tersebut. Oleh sebab itu, dibutuhkan metode untuk mengukur seberapa besar *error* yang dapat dihasilkan oleh metode-metode *forecasting* untuk dipertimbangkan kembali sebelum dibuat keputusan. Metode-metode yang dapat digunakan dalam mengevaluasi *error* pada teknik *forecasting* yaitu

MSE (*mean square error*), RMSE (*root mean square error*), MAD (*mean absolute derivation*), MAPE (*mean absolute percentage error*) dan MPE (*mean percentage error*).

Metode yang paling umum digunakan yaitu MSE (*mean square error*), RMSE (*root mean square error*). MSE mengukur rata-rata kuadrat dari kesalahan antara target yang diamati dan nilai yang diprediksi. Semakin kecil MSE, semakin baik hasil prediksi yang dihasilkan.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (2.13)$$

dengan:

$n$  = jumlah titik data

$\hat{Y}_i$  = nilai prediksi

$Y_i$  = nilai aktual

Karena MSE diukur dalam satuan kuadrat, maka RMSE dapat ditafsirkan sebagai jarak rata-rata, antara nilai yang diprediksi dan diamati, diukur dalam satuan variabel target.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2.14)$$

### III. METODOLOGI PENELITIAN

#### 3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2021/2022 bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

#### 3.2 Data Penelitian

Data yang digunakan pada penelitian ini merupakan data sekunder yang bersumber dari penelitian sebelumnya. Data sekunder adalah data penelitian yang sudah tersedia dan dikumpulkan oleh pihak lain (Anwar, 2014). Data tersebut merupakan data bendungan batu tegi berupa debit inflow dari tahun 2018-2020 dengan hari aktif sebanyak 1096 data. Sebanyak 75% dari data digunakan untuk data *training* dan 25% dari data digunakan untuk data *testing*. Proses pelatihan ini menggunakan R Studio.versi 4.0.3.

#### 3.3 Metode Penelitian

Tahapan metode *Backpropagation* adalah sebagai berikut:

- a. Inisialisasi bobot (tetapkan bobot awal dengan nilai random cukup kecil).
- b. Tetapkan : maksimum *Epoch*, target *Error*, dan *Learning Rate* ( $\alpha$ ).
- c. Inisialisasi :  $Epoch = 0$ ,  $mean\ square\ error = 1$ .

Siang (2009) menyatakan bahwa algoritma pelatihan untuk jaringan

*Backpropagation* adalah sebagai berikut:

**Langkah 1** : Menetapkan nilai *input*.

**Langkah 2** : Membuat inisialisasi semua bobot dengan bilangan acak kecil (Siang, 2009).

**Fase I : Propagasi Maju (*Forward Propagation*)**

**Langkah 3** : Tiap unit masukan  $X_i$  ( $i=1,2,3,\dots,n$ ) menerima sinyal  $X_i$  dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya.

**Langkah 4** : Tiap-tiap unit lapisan tersembunyi  $Z_j$  ( $j=1,2,3,\dots,p$ ) menjumlahkan sinyal-sinyal *input* terbobot:

$$Z_{in_j} = V_{oj} + \sum_{i=1}^n X_i V_{ij} \quad (3.1)$$

Kemudian nilai keluaran atau input dihitung menggunakan fungsi aktivasi. Selanjutnya sinyal tersebut dikirimkan ke semua unit di lapisan atasnya.

**Langkah 5** : Hasil fungsi tersebut dikirim ke semua unit pada lapisan di atasnya. Tiap-tiap unit keluaran  $Y_k$  ( $k=1,2,3,\dots,m$ ) menjumlahkan sinyal-sinyal *input* terbobot.

$$Y_{in_k} = W_{ok} + \sum_{j=1}^p Z_j W_{jk} \quad (3.2)$$

Kemudian dihitung nilai keluaran dengan menggunakan fungsi aktivasi. Kemudian kirimkan sinyal tersebut ke semua unit di lapisan atasnya.

**Fase II : Propagasi Mundur (*Backpropagation*)**

**Langkah 6** : Tiap-tiap unit keluaran  $Y_k$  ( $k=1,2,3,\dots,m$ ) menerima target pola yang berhubungan dengan pola *input* pembelajaran, hitung informasi *error*.

$$\begin{aligned} \delta_k &= (t_k - Y_k) f(Y_{in_k}) \\ &= (t_k - Y_k)(1 - Y_k) \end{aligned} \quad (3.3)$$

Kemudian hitung koneksi nilai bobot yang kemudian akan digunakan untuk memperbaharui nilai  $W_{jk}$ :

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (3.4)$$

Koreksi nilai *bias* dihitung yang selanjutnya akan digunakan untuk memperbaharui nilai *Wok*:

$$\Delta W_{ok} = \alpha \delta_k \quad (3.5)$$

Kirimkan  $\delta k$  ke unit-unit yang ada dilapisan bawahnya.

**Langkah 7** : Tiap-tiap unit *hidden*  $Z_j$  ( $j=1,2,3,\dots,p$ ) menjumlahkan *delta input* (dari unit unit yang berada pada lapisan di atasnya):

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \quad (3.6)$$

Selanjutnya nilai tersebut dikalikan dengan nilai turunan fungsi aktivasi untuk menghitung error atau informasi kesalahan.

Penghitungan koreksi nilai bobot yang akan digunakan untuk memperbaiki nilai  $V_{ij}$ :

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (3.7)$$

Koreksi nilai *bias* dihitung yang selanjutnya digunakan untuk memperbaharui atau memperbaiki nilai  $V_{oj}$ :

$$\Delta V_{jk} = \alpha \delta_j \quad (3.8)$$

**Fase III** : **Perubahan Bobot**

**Langkah 8** : Tiap-tiap unit *output*  $Y_k$  ( $k=1,2,3,\dots,m$ ) memperbaiki *bias* dan bobotnya ( $j=1,2,3,\dots,p$ ):

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (3.9)$$

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

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (3.10)$$

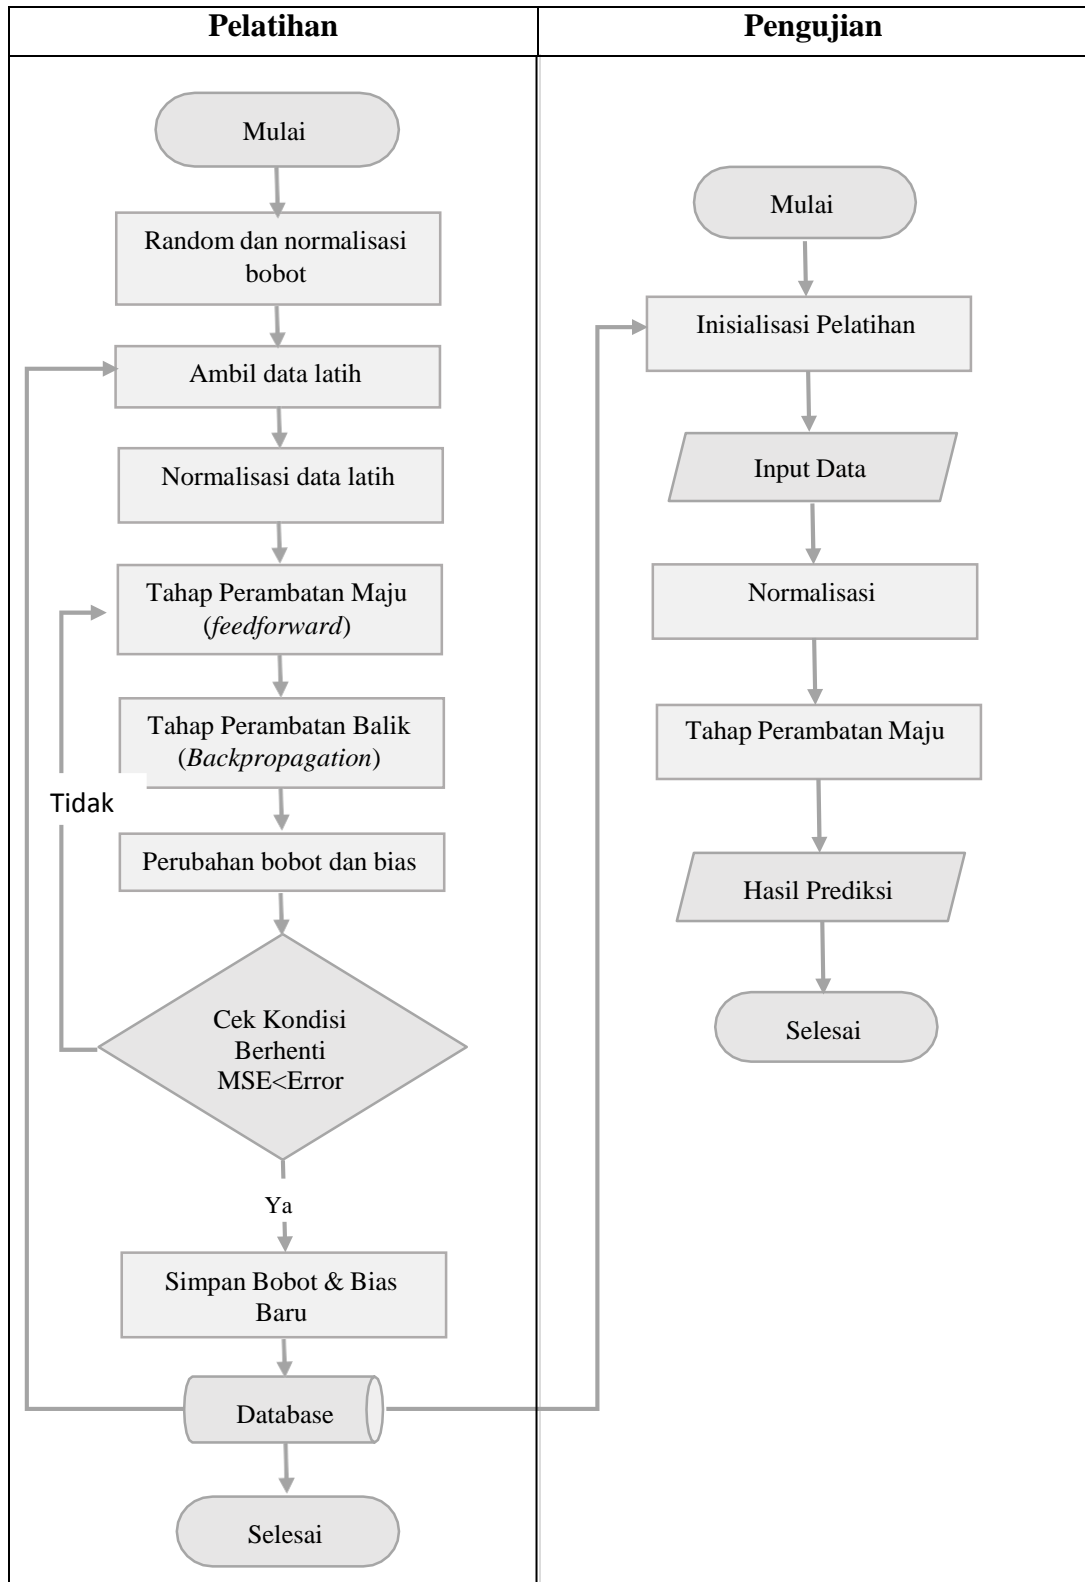
**Langkah 9** : : Menghitung *mean square error*, jika nilai *mean square error* belum lebih kecil daripada target *error*, maka langkah 2-8 terus dilakukan.

Simbol-simbol algoritma *artificial neural network Backpropagation* akan diterangkan dan dijelaskan pada tabel 1 sebagai berikut:



Tabel 1. Simbol-simbol Algoritma *Backpropagation*

No.	Simbol	Keterangan
1	$X$	<i>Input vektor pelatihan, (<math>i=1,2,3,\dots,n</math>)</i>
2	$Y$	<i>Output vector target, <math>Y_k(k=1,2,3,\dots,m)</math></i>
3	$\delta_k$	Informasi tentang kesalahan pada unit $Y_k$ yang disebarkan kembali ke unit tersembunyi
4	$\delta_j$	Informasi tentang kesalahan dari lapisan <i>output</i> ke unit tersembunyi $Z_j$
5	$\alpha$	Laju pembelajaran ( <i>learning rate</i> )
6	$X_i$	Unit input $i$
7	$V_{oj}$	<i>Bias pada lapisan tersembunyi <math>j</math></i>
8	$Z_j$	Unit tersembunyi $j$
9	$Z_{in_j}$	<i>Input jaringan ke <math>Z_j</math></i>
10	$V_{ok}$	<i>Bias pada unit tersembunyi <math>k</math></i>
11	$Y_k$	Unit output $i$
12	$Y_{in_k}$	<i>Input jaringan ke <math>Y_k</math></i>



Gambar 9. *Flowchart* Sistem Pelatihan dan Pengujian Algoritma *Backpropagation*.

## V. KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan pembahasan mengenai pembentukan model *Feedforward Neural Network* dengan algoritma *Backpropagation* yang diterapkan untuk meramalkan debit *inflow*, maka dapat disimpulkan sebagai berikut:

1. Prosedur pembentukan model *Feedforward neural network* dengan algoritma *Backpropagation* pada data *time series* terdiri atas beberapa tahap, yaitu (1) pemeriksaan data *missing*, (2) menentukan input, (3) melakukan pembagian data menjadi 2 yaitu data *training* dan data *testing*, (4) normalisasi data, (5) membangun model *Feedforward neural network* dengan algoritma *Backpropagation*, yaitu menentukan banyaknya neuron pada lapis tersembunyi, menentukan input, dan menentukan bobot model, dan (6) denormalisasi.
2. Model FFNN dengan algoritma *Backpropagation* ini diterapkan pada data debit *inflow* bendungan Batu Tegi tanggal 1 Januari 2018 sampai 31 Desember 2020 dengan variabel *input* yang digunakan yaitu debit *inflow* Lag 1, Lag 2, Lag 3, Lag 4, Lag 5, Lag 6, Lag 7, Lag 9 dan Lag 10. Berdasarkan hasil numerik pada Tabel 17 dengan *error* terkecil 0,153388, struktur jaringan terbaik yang diperoleh adalah dengan 9 *neuron input*, 9 *neuron* pada lapis tersembunyi pertama dan 4 *neuron* pada lapis tersembunyi kedua dengan menggunakan fungsi aktivasi Sigmoid.

3. Prediksi debit *inflow* tersebut menghasilkan akurasi sebesar 99,6687%, maka dapat disimpulkan bahwa model layak untuk digunakan dalam meramalkan debit *inflow* periode berikutnya yaitu 1 Januari 2021. Hasil peramalan untuk periode berikutnya pada tanggal 1 Januari 2021 yaitu sebesar 29,62063 m<sup>3</sup>/det, dan untuk peramalan periode seterusnya dilakukan dengan cara yang sama.

## 5.2 Saran

Peneliti mengkaji tentang *machine learning* yaitu metode *Backpropagation* dalam bidang peramalan debit *inflow* Bendungan Batu Tegi. Penelitian selanjutnya masih dapat mengembangkan lagi pada bidang *machine learning* lainnya misalkan menggunakan pengembangan metode dari *Extreme Learning Machine* contohnya *Genetic Algorithm-Extreme Learning Machine* (GA-ELM), *Particle Swarm Optimization- Extreme Learning Machine* (PSO-ELM), dan *Ant Colony Optimization- Extreme Learning Machine* (ACO-ELM) mengingat cakupan analisis peramalan yang sangat luas.

## DAFTAR PUSTAKA

- Amran, Yusuf. 2012. Pemberdayaan Masyarakat Dalam Rangka Pengelolaan Waduk dan Daerah Tangkapan Air Waduk Batu Tegi. *TAPAK(Teknologi Aplikasi Konstruksi)*. 2(1): 50-55.
- Asdak, Chay. 2001. *Hidrologi dan Pengelolaan Daerah Aliran Sungai*. Universita Gadjah Mada, Yogyakarta.
- Chang, P.C., Wang, Y-W., & Liu, C-H. 2007. The Development of A Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. *Expert Systems with Applications*. 32 : 86-96.
- Chiamsathit, C., Adeloye. A.J., & Bankaru-S, S. 2016. Inflow Forecasting Using Artificial Neural Networks for Reservoir Operation. *The Spatial Dimensions of Water Management – Redistribution of Benefits and Risks*. 373: 209-214.
- Elmasari, Y. & Nurhadi. 2019. Optimasi *Artificial Neural Network* dengan *Genetic Algorithm* pada Prediksi Debit *Inflow* Waduk Sengguruh. *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*. 4(2): 122-126.
- Fausett, L. 1994. *Fundamentals of Neural Networks Achitectures, Algorithms and Applications*. Prentice Hall, New Jersey.
- Hanke, J.E. & Wichern, D.W. 2014. *Business Forecasting*. 9th Edition. Pearson,USA.
- Heaton, J. 2008. *Introduction to Neural Networks with Java Second Edition*. Heaton Research, United States of Amerika.

- Heizer, J. & Render, B. 2006. *Manajemen Operasi edisi 7*. Salemba, Jakarta.
- Herawati, H., Suripin, & Suharyanto. 2017. River Flow Modeling Using Artificial Neural Networks In Kapuas River, West Kalimantan, Indonesia. *AIP Conference Proceedings*. **1903**: 100010-1 – 100010-7.
- Hermawan, A. 2006. *Pengantar Jaringan Syaraf Tiruan, Teori, dan Aplikasi*. Andi, Yogyakarta.
- Huang, G.B. 2003. Learning Capability and Storage Capacity of Two-Hidden-Layer Feedforward Networks. *IEEE Transactions On Neural Networks*. **14**(2): 274-281
- James, G., Witten, D., Hastie, T., & Tibshirani, R. 2013. *An Introduction to Statistical Learning With Applications in R*. Pearson Education, New York.
- Kartasapoetra, A.G. & Sutedjo, M.M. *Teknologi Pengairan Pertanian Irigasi*. Bumi Aksara, Jakarta.
- Khashei, M. & Bijari, M. 2010. An Artificial Neural Network (p, d, q) model for time series forecasting. *International Journal of Expert System with Applications* **37**(1): 479-489.
- Kristanto, A. 2004. *Jaringan Syaraf Tiruan, Konsep Dasar, Algoritma dan Aplikasinya*. Gava Media, Yogyakarta.
- Kusumadewi, S. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu, Yogyakarta.
- Kuswanto, Dedy. 2012. *Statistik Untuk Pemula & Orang Awam*. Laskar, Jakarta.
- Lewis, N., D. 2017. *Neural Network For Time Series Forecasting With R*. Pearson Education, New York.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. Binarupa Aksara, Jakarta.

- Puspitaningrum, D. 2006. *Pengantar Jaringan Syaraf Tiruan*. Andi Offset, Yogyakarta.
- Rezaei, M., Motlaq, A.A.A., Mahmoudi, A.R., & Mousavi, H. 2015. River Flow Forecasting Using Artificial Neural Network (Shoor Ghaen). *Ciencia E Natura*. **37**(1): 207-215.
- Ridwan, Sudira, P., Susanto, S., & Sutiaarso, L. 2013. Manajemen Sumber Daya Air Daerah Aliran Sungai Sekampung di Antara Bendungan Batuteги dan Bendung Argoguruh, Provinsi Lampung: Kerangka Analitis Penyusunan Pola Operasional Harian. *AGRITECH*. **33**(2): 226-233.
- Santoso, Singgih. 2009. Business forecasting. Penerbit PT. Elex Media Komputindo, Jakarta.
- Sanusi, Anwar. 2014. *Metodologi Penelitian Bisnis*. Penerbit Salemba Empat, Jakarta.
- Sarono, E.W. & Asmoro, W. 2007. *Evaluasi Kinerja Waduk Wadaslintang*. Tugas Akhir Jurusan Teknik Sipil, Fakultas Teknik Universitas Diponegoro.
- Shamseldin, A.Y. 2010. Artificial Neural Network Model for River Flow Forecasting In A Developing Country. *Journal of Hydroinformatics*. **12**(1): 22-35
- Siang, J. J. 2009. *Jaringan Syaraf Tiruan & Pemogramannya Menggunakan Matlab*. Penerbit Andi, Yogyakarta.
- Sugiyono. 2007. *Statistik Untuk Penelitian*. Alfabeta, Bandung.
- Supriyadi, E., Banuwa, I.S., & Yuwono, S.B. 2018. Pengaruh Perubahan Penggunaan Lahan Terhadap Karakteristik Aliran Masuk (*Inflow*) Bendungan Batuteги. *Jurnal Hutan Tropis*. **6**(1): 73-81
- Susilowati. 2007. Analisis Hidrograf Aliran Sungai dengan Adanya Beberapa Bendung Kaitanya dengan Konservasi Air (Tesis). Program Studi Ilmu Lingkungan FMIPA UNS, Surakarta.

Walpole, R. E., Mayers, R. H., Mayers, S. L., & Ye, K. 2011. *Probability & Statistics for Engineers & Scientists 9th Ed.* Person, United States Amerika.

Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods Second Edition.* Pearson Education, New York.

Xu, Z.X., & Li, J.Y. 2002. Short-term Inflow Forecasting Using An Artificial Neural Network Model. *Hydrological Processes*. **16**: 2423-2439.