

BAB 2 LANDASAN KEPUSTAKAAN

Bab ini menjelaskan tentang kajian pustaka yang dilakukan beserta dasar teori yang berisi tentang segala hal yang berkaitan dengan penelitian ini seperti jumlah kasus penyakit, penyakit demam *tifoid-paratifoid* dan *Nasofaringitis akut*, peramalan serta metode *Backpropagation*.

2.1 Kajian Pustaka

Pada bagian kajian pustaka ini, dilakukan kajian-kajian dari penelitian sebelumnya yang salah satunya dilakukan oleh Abdellah dan Djamel (2013) pada penelitiannya yang berjudul "*Forecasting the Algerian Load Peak Profile Using Time Series Model Based On Backpropagation Neural Networks*" menerapkan metode *Backpropagation Neural Network* dalam melakukan peramalan data runtun waktu (*time series*) beban tenaga listrik tertinggi (*peak load*) di negara Algeria. Dalam penelitiannya, digunakan data set sebanyak 23 bulan dari bulan Maret 2010 hingga Februari 2012 untuk melakukan data training. Hasil yang didapatkan adalah memuaskan meskipun bisa didapatkan hasil yang lebih baik dengan menambah data set yang lebih banyak.

Penelitian selanjutnya dilakukan oleh Baboo dan Shereef (2010) yang pada penelitiannya melakukan peramalan menggunakan metode *Backpropagation Neural Network* pada data set temperatur secara *real time*. Penelitian ini didasari dengan pentingnya mengetahui kondisi cuaca karena cuaca sangat berpengaruh pada kondisi dan kesejahteraan daerah. Dengan adanya peramalan cuaca yang cepat dan akurat dapat membantu permasalahan yang berhubungan dengan cuaca. Berdasarkan hasil permodelan *Backpropagation Neural Network* dalam melakukan peramalan cuaca, didapatkan hasil yang baik dengan error yang termasuk sedikit. Hasil yang baik tersebut dapat digunakan sebagai pertimbangan untuk memilih metode yang digunakan untuk peramalan cuaca.

Penelitian selanjutnya dilakukan oleh Tsong Lin Lee (2013) yang pada penelitiannya menerapkan metode *Backpropagation Neural Network* untuk memprediksi pasang surut air laut. Penelitian ini didasari oleh meningkatnya kebutuhan prediksi pasang surut air laut yang cepat dan akurat, karena pada dasarnya pasang surut air laut berhubungan dengan pergerakan sedimen, polutan, penerapan keilmuan di bidang tersebut, hingga eksplorasi dan *oceanography*. Berdasarkan pentingnya mengetahui pasang surut air laut tersebut, prediksi pasang surut secara cepat dan akurat. Dalam penelitian ini, ditawarkan peramalan pasang surut air laut secara jangka panjang menggunakan metode jaringan saraf tiruan *Backpropagation*. Hasil yang didapatkan adalah termasuk dalam level memuaskan, serta mampu melakukan peramalan dengan baik pada data set yang memiliki variasi level.

Penelitian selanjutnya dilakukan oleh Li Yizhen dan Zeng Wenhua (2011) yang pada penelitiannya menerapkan metode *Genetic Algorithm* dan *Backpropagation Neural Network* untuk melakukan peramalan trending index pasar saham di Shanghai. Pentingnya mengetahui harga saham didalam

melakukan jual-beli saham menjadi salah satu pendukung dalam melakukan penelitian ini. Tidak hanya mampu memprediksi dengan cepat, namun juga akurat dalam memberikan prediksi harga saham. Berdasarkan permodelan menggunakan *Backpropagation Neural Network* untuk melakukan peramalan di Shanghai, didapatkan hasil yaitu *Backpropagation Neural Network* menghasilkan peramalan tren index pasar saham yang optimal. Penggunaan *Genetic Algorithm* untuk mengoptimasi parameter *Backpropagation Neural Network* dapat meningkatkan akurasi peramalan.

Penelitian selanjutnya dilakukan oleh Havaluddin dan Alfred (2015) yang pada penelitiannya menerapkan metode *Genetic Algorithm* dan *Backpropagation Neural Network* untuk melakukan peramalan pada data runtun waktu (*time series*). Penelitian ini bertujuan untuk mengetahui akurasi peramalan pada data *time series*. Hasil dari penelitian ini didapatkan bahwa *Backpropagation Neural Network* dapat memberikan hasil peramalan yang baik, dan dengan mengimplementasikan *Genetic Algorithm* untuk optimasi dapat meningkatkan akurasi peramalan.

Pada penelitian ini, berbeda dengan penelitian sebelumnya yaitu objek penelitian yang digunakan adalah jumlah kasus penyakit. Metode yang digunakan adalah *Backpropagation Neural Network* yang diimplementasikan pada data set *time series* dari Puskesmas Rogotrunan Lumajang. Data dan metode tersebut digunakan untuk melakukan peramalan jumlah kasus penyakit sehingga didapatkan akurasi dari peramalan menggunakan *Backpropagation Neural Network*.

Tabel 2.1 Kajian Pustaka

No.	Judul	Objek	Metode	Hasil
1.	<i>Forecasting the Algerian Load Peak Profile Using Time Series Model Based On Backpropagation Neural Networks</i> (Abdellah dan Djamel, 2013)	Beban Tenaga Listrik Tertinggi di Algeria	<i>Backpropagation Neural Network</i>	Hasil peramalan yang didapat cukup baik. Untuk mendapatkan hasil yang lebih baik data set yang digunakan harus ditambah.
2.	<i>An Efficient Weather</i>	Cuaca dan Temperatur	<i>Backpropagation Neural Network</i>	Hasil implementasi <i>Backpropagation</i>

	<p><i>Forecasting System using Artificial Neural Network</i></p> <p>(Baboo dan Shereef, 2010)</p>			<p><i>Neural Network</i> pada peramalan menunjukkan bahwa sistem dapat terintegrasi dengan sangat baik serta menunjukkan akurasi peramalan yang baik.</p>
3.	<p><i>Back-propagation neural network for long-term tidal predictions</i></p> <p>(Tsong Lin Lee, 2003)</p>	<p>Pasang Surut Air Laut</p>	<p><i>Backpropagation Neural Network</i></p>	<p>Hasil dari peramalan menunjukkan bahwa <i>Backpropagation Neural Network</i> termasuk memuaskan dalam menangani peramalan pasang surut air laut yang memiliki variasi level data.</p>
4.	<p><i>The forecasting of Shanghai Index trend Based on Genetic Algorithm and Back Propagation Artificial Neural Network Algorithm</i></p> <p>(Li Yizhen dan Zeng Wenhua, 2011)</p>	<p>Trending Index Pasar Saham Shanghai</p>	<p><i>Genetic Algorithm dan Backpropagation Neural Network</i></p>	<p>Hasil penelitian didapatkan bahwa penggunaan <i>Genetic Algorithm</i> dikombinasikan dengan <i>Backpropagation</i> dapat meningkatkan akurasi peramalan trending index pasar saham. Penggunaan <i>Backpropagation</i> dirasa optimal dalam melakukan peramalan.</p>

5.	<i>A Genetic-Based Backpropagation Neural Network for Forecasting in Time-Series Data</i> (Haviluddin dan Alfred, 2015)	Data Time Series (<i>Network Traffic</i>)	<i>Genetic Algorithm</i> dan <i>Backpropagation Neural Network</i>	Hasil peramalan dengan menerapkan <i>Backpropagation Neural Network</i> memberikan hasil yang baik, dengan menambah <i>Genetic Algorithm</i> untuk optimasi dapat meningkatkan akurasi peramalan.
----	--	--	--	---

2.2 Jumlah Kasus Penyakit

Jumlah kasus penyakit merupakan kumpulan kasus penyakit yang dikategorikan menurut kelompok penyakit di Indonesia. Riskesdas 2007 (Riset Kesehatan Daerah tahun 2007) mengelompokkan penyakit penyebab kematian menjadi 4 kelompok yaitu:

1. Penyakit Menular.
2. Penyakit Tidak Menular.
3. Gangguan Maternal/Perinatal.
4. Cidera.

2.2.2 ICD 10

Di skala Internasional, standar pengelompokan penyakit dikeluarkan oleh WHO (*World Health Organization*) yang biasa disebut ICD (*International Statistical Classification of Diseases and Related Health Problems*). Saat ini, ICD telah direvisi sebanyak 10 kali (WHO, 2016). Di Indonesia sendiri kategori penyakit yang sesuai dengan standar Internasional ICD10 dapat dilihat di Tabel 2.2

Tabel 2.2 Klasifikasi ICD10

1	<u>A00-B99</u>	Penyakit yang tergolong Infeksi dan parasit
2	<u>C00-D48</u>	Penyakit Neoplasma
3	<u>D50-D89</u>	Penyakit pada darah serta gangguan imunitas
4	<u>E00-E90</u>	Endokrin, nutrisi serta gangguan metabolik
5	<u>F00-F99</u>	Gangguan jiwa dan perilaku tidak normal
6	<u>G00-G99</u>	Penyakit pada sistem saraf dan neuron
7	<u>H00-H59</u>	Penyakit mata serta adnexa
8	<u>H60-H95</u>	Penyakit telinga serta mastoid
9	<u>I00-I99</u>	Penyakit yang ada pada sistem sirkulasi

10	<u>J00-J99</u>	Penyakit sistem pernafasan
11	<u>K00-K93</u>	Penyakit sistem pencernaan
12	<u>L00-L99</u>	Penyakit kulit serta jaringan subcutaneous
13	<u>M00-M99</u>	Penyakit sistem musculoskeletal
14	<u>N00-N99</u>	Penyakit sistem saluran kemih serta kelamin
15	<u>O00-O99</u>	Kehamilan serta kelahiran
16	<u>P00-P96</u>	Keadaan yg berasal dari periode perinatal
17	<u>Q00-Q99</u>	Malformasi kongenital, deformasi serta kelainan chromosom
18	<u>R00-R99</u>	Gejala, tanda, kelainan klinik serta kelainan pada hasil laborat yang tidak ada di klasifikasi lain
19	<u>S00-T98</u>	Keracunan, cedera serta penyakit disebabkan dari luar
20	<u>V01-Y98</u>	Penyebab morbiditas serta kematian eksternal
21	<u>Z00-Z99</u>	Faktor faktor yang mempengaruhi status kesehatan serta hubungannya dengan jasa kesehatan
22	<u>U00-U99</u>	Kode yang digunakan untuk kasus khusus

Sumber: WHO, 2016

Penggunaan ICD 10 di Indonesia mulai digunakan sejak adanya keputusan Direktur Jenderal Pelayanan Medik (Dirjen Yanmed) no: HK 00 . 05 . 1 . 4 . 00744 mengenai penggunaan klasifikasi Internasional mengenai penyakit revisi ke sepuluh (ICD-10) di Rumah Sakit pada tanggal 19 Februari 1996.

2.3 Penyakit Demam *Tifoid-Paratifoid* dan *Nasofaringitis akut*

Demam *Tifoid-Paratifoid* dan *Nasofaringitis akut* adalah salah satu penyakit yang terdapat pada klasifikasi penyakit ICD10 dan akan digunakan pada penelitian ini.

2.3.1 Demam *Tifoid-Paratifoid*

Demam *tifoid* dan *paratifoid* adalah penyakit yang termasuk dalam bagian *chapter 1/I* dari klasifikasi penyakit ICD10, *chapter 1/I* adalah bagian penyakit infeksi dan parasit (WHO, 2016).

Demam *tifoid* ini merupakan penyakit yang tergolong berpotensi berbahaya dan kadang mampu menyebabkan kematian. Penyakit ini disebabkan oleh bakteri *Salmonella enterica* serotipe Typhi. Sedangkan demam *paratifoid* adalah penyakit serupa namun disebabkan oleh bakteri berbeda yaitu *Salmonella enterica* serotipe Paratyphi A, B (tartrate negatif), atau C (Newton, Ruth & Mahon, 2015). Penyakit ini banyak ditemukan khususnya di Asia Tenggara, karena setiap tahun di Amerika Serikat lebih dari 80% dari laporan demam *tifoid* dan lebih dari 90% dari laporan

demam *paratifoid* disebabkan oleh *Salmonella* paratipe A adalah wisatawan dari Asia Selatan (Newton, Ruth & Mahon, 2015).

Penyakit ini memiliki data dengan minimalitas data kosong yang tinggi pada data set penelitian ini, serta memiliki variasi parameter.

2.3.2 Nasofaringitis akut

Nasofaringitis akut adalah salah satu penyakit yang terdapat pada klasifikasi penyakit ICD10 dan akan digunakan pada penelitian ini. Penyakit *nasofaringitis akut* adalah penyakit yang termasuk dalam bagian *chapter 10/X* dari klasifikasi penyakit ICD10, *chapter 10/X* adalah bagian penyakit pada sistem pernafasan (WHO, 2016).

Nasofaringitis akut ini merupakan penyakit yang tergolong pada penyakit infeksi saluran pernafasan atas. Penyakit ini umumnya disebut pilek/flu (*common cold*), yang disebabkan oleh infeksi virus pada mukosa saluran pernafasan atas. Gejala yang biasa terjadi pada penyakit ini adalah rasa tidak enak, hidung berair, bersin-bersin, tenggorokan kering atau gatal. Sakit kepala, konjungtivitis ringan (mata merah), suara serak dan batuk juga kadang-kadang bisa dilihat pada pasien yang terkena *nasofaringitis akut* (Rabkin, 2017).

Majoritas *nasofaringitis akut* (*common cold*) disebabkan oleh 4 keluarga yang berbeda dari virus yaitu *rhinovirus*, *coronavirus*, *adenovirus*, dan virus pernafasan. Meskipun ada variasi musiman dari virus-virus tersebut, namun gejala yang dihasilkan hampir tidak bisa dibedakan (Rabkin, 2017). Penyakit ini akan digunakan sebagai data set dari penelitian, selain memiliki minimalitas data kosong yang tinggi penyakit ini juga memiliki variasi parameter yang dapat digunakan.

2.4 Peramalan

Peramalan (*forecasting*) merupakan suatu perhitungan ilmiah yang bertujuan untuk memprediksikan keadaan di masa yang akan datang dengan menggunakan data dan informasi pada masa lalu (Adam & Ebert, 1982). Dalam sumber lain, peramalan adalah suatu proses untuk memperkirakan suatu nilai pada periode waktu tertentu di masa yang akan datang menggunakan penjelasan secara statistik dan matematik (Muqtadiroh et al., 2015). Peramalan telah banyak digunakan dalam berbagai bidang atau kasus, dikarenakan pentingnya mengetahui informasi dan data yang akan datang supaya dapat mempersiapkan sebelum terjadi. Luthfianto (2011) pada penelitiannya menyatakan bahwa peramalan merupakan salah satu faktor penting dalam mengambil keputusan pada organisasi bisnis serta dapat digunakan untuk melakukan perencanaan jangka panjang pada perusahaan atau instansi tertentu.

2.4.1 Jenis-jenis Peramalan

Peramalan pada dasarnya memiliki beberapa macam, peramalan secara umum dapat dibedakan yaitu:

2.4.1.1 Berdasarkan Jangka Waktu

1. Peramalan jangka pendek, yaitu peramalan yang dilaksanakan pada jangka waktu kurang dari satu tahun. Peramalan ini umum digunakan pada penjadwalan kelas serta perencanaan belanja.
2. Peramalan jangka menengah, yaitu peramalan yang dilaksanakan pada jangka waktu kurang dari tiga tahun. Peramalan ini umum digunakan pada perencanaan produksi pabrik serta perencanaan penjualan pabrik.
3. Peramalan jangka panjang, yaitu peramalan yang dilaksanakan pada jangka waktu lebih dari tiga tahun. Peramalan ini umum digunakan pada perencanaan anggaran modal perusahaan serta perencanaan kondisi cuaca suatu daerah.

2.4.1.2 Berdasarkan Metode

1. Peramalan kualitatif, yaitu peramalan yang menggunakan data kualitatif (non-numerik) sebagai data-setnya. Pada dasarnya proses dan hasil dari peramalan ini bersifat subjektif, yaitu bergantung pada opini serta pengetahuan penyusunnya (Muqtadiroh et al., 2015).
2. Peramalan kuantitatif, yaitu peramalan yang menggunakan data kuantitatif (numerik) sebagai data-setnya. Pada dasarnya proses dan hasil dari peramalan ini bergantung dari metode yang diimplementasikan (Muqtadiroh et al., 2015). Terdapat dua jenis metode peramalan kuantitatif yaitu:
 - a. Metode *Time Series*, metode yang digunakan untuk melakukan peramalan pada data set runtun waktu (*time series*).
 - b. Metode *Causal*, metode yang digunakan untuk melakukan peramalan pada data set yang memiliki hubungan sebab-akibat.

2.4.2 Proses Peramalan

Montgomery et al. (2008) menjelaskan bahwa terdapat beberapa tahapan di dalam proses peramalan, yaitu:

1. Mendefinisikan permasalahan.
2. Mengumpulkan data.
3. Menganalisis data.
4. Menyeleksi permodelan data.
5. Memvalidasi model peramalan.
6. Menerapkan model peramalan.
7. Evaluasi model peramalan.

2.4.3 Mengukur Akurasi Peramalan

Pada penelitian peramalan, hasil yang didapatkan perlu diukur tingkat keakuratannya dengan melakukan pengukuran akurasi peramalan. Kesalahan-kesalahan yang umum terjadi pada peramalan adalah salah satu kekurangan dari sistem dalam memodelkan data serta mengenali unsur dalam data yang tidak digunakan. Kekurangan tersebut biasa disebut faktor tidak terduga dimana tidak ada metode peramalan yang mampu melakukan peramalan dengan tanpa kesalahan.

Selain itu, ketidakcocokan penggunaan metode dalam mengenali data merupakan salah satu faktor dari kekurangan hasil peramalan (Bowerman et al., 1987 dalam Sungkawa, 2011). Terdapat beberapa cara dalam mengukur akurasi peramalan, salah satunya adalah secara statistik yaitu:

1. *Mean Error* (ME)

$$ME = \frac{\sum_{t=1}^n e_t}{n} \quad (2.1)$$

Dimana:

e_t = error pada periode t
 n = jumlah data uji

2. *Mean Absolute Deviation* (MAD)

$$MAD = \frac{\sum_{t=1}^n |e_t|}{n} \quad (2.2)$$

Dimana :

e_t = error pada periode t
 n = jumlah data uji

3. *Mean Squared Error* (MSE)

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n} \quad (2.3)$$

Dimana:

e_t = error pada periode t
 n = jumlah data uji

4. *Standard Deviation Error* (SDE)

$$SDE = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n-1}} \quad (2.4)$$

Dimana:

e_t = error pada periode t
 n = jumlah data uji

Selain itu terdapat cara mengukur akurasi peramalan secara relatif, yaitu:

1. *Percentage Error* (PE)

$$PE_t = \left[\frac{X_t - F_t}{X_t} \right] \cdot 100 \quad (2.5)$$

Dimana:

X_t = data aktual periode t
 F_t = data hasil peramalan periode t

2. *Mean Percentage Error* (MPE)

$$MPE = \frac{\sum_{t=1}^n PE_t}{n} \quad (2.6)$$

Dimana:

PE_t = Percentage Error (PE) periode t
 n = jumlah data uji

3. Mean Absolute Percentage Error (MAPE)

$$MAD = \frac{\sum_{t=1}^n |PE_t|}{n} \quad (2.7)$$

Dimana:

PE_t = Percentage Error (PE) periode t
 n = jumlah data uji

Sementara pada penelitian ini akan digunakan *Mean Squared Error* (MSE) dalam mengukur akurasi peramalan. Sesuai dengan penelitian yang dilakukan oleh (Bowerman et al., 1987 dalam Sungkawa, 2011) yang menggunakan MSE dalam mengukur akurasi peramalan.

2.5 Backpropagation

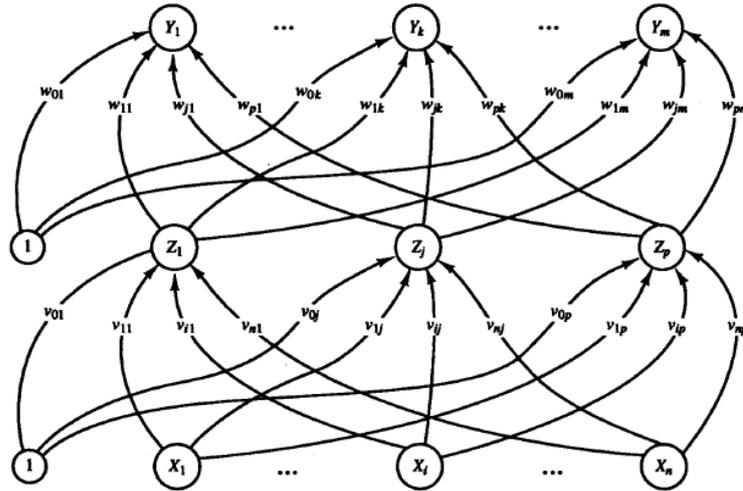
Backpropagation adalah salah satu algoritma pembelajaran yang umumnya diterapkan pada peramalan dan merupakan bagian dari jaringan saraf tiruan. Algoritma backpropagation biasa digunakan untuk peramalan (*forecasting*) dengan menggunakan perceptron yang memiliki banyak lapisan (*multi-layer*). Perceptron tersebut nantinya digunakan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang terdapat pada lapisan tersembunyi (*hidden layer*) (Handayani, 2013). *Backpropagation* memiliki dua tahap yaitu umpan maju (*feedforward*) dan umpan mundur. Disaat tahapan umpan maju (*feedforward*) berjalan, setiap unit input akan menerima sinyal input yang selanjutnya akan meneruskan sinyal tersebut pada tiap-tiap *hidden unit* pada *hidden layer*.

2.5.1 Arsitektur Jaringan Backpropagation

Arsitektur jaringan algoritma *backpropagation* pada dasarnya tersusun dari beberapa layer, yaitu layer masukan (*input layer*), layer tersembunyi (*hidden layer*) serta layer keluaran (*output layer*). Cara kerja jaringan *backpropagation* adalah apabila masukan datang melalui *input layer*, maka masukan akan dipropagasikan melewati setiap layer yang ada di atasnya hingga menghasilkan keluaran (*output*) dari jaringan tersebut. Keluaran (*output*) tersebut kemudian dibandingkan dengan target keluaran (*target output*), sehingga akan menghasilkan jarak ketidakcocokan/ *miss range* antara keluaran (*output*) dan target keluaran (*target output*). Ketidakcocokan tersebut biasa disebut nilai *error*.

Setelah itu jaringan akan meneruskan turunan dari *error* tersebut ke *hidden layer* menggunakan bobot yang belum diubah nilainya. Selanjutnya setiap neuron pada *hidden layer* menghitung jumlah bobot dari *error* yang telah dipropagasikan sebelumnya. Setelah semua neuron dari *hidden layer* dan *output layer*

mendapatkan besar *error*, maka neuron tersebut merubah nilai bobotnya untuk mengurangi nilai *error*. Proses ini akan berlangsung berulang-kali sampai error yang didapatkan dari jaringan mendekati nol (Giantara, 2013). Arsitektur jaringan *backpropagation* (Fausett, 1994) dapat dilihat pada Gambar 2.1



Gambar 2.1 Arsitektur Jaringan *Backpropagation*

Keterangan:

- X = *input layer*
- Z = *hidden layer*
- Y = *output layer*
- W = bobot antara X dan Z

2.5.2 Fungsi Aktivasi

Fungsi Aktivasi merupakan nilai keluaran (*output*) dari sebuah neuron yang ada pada level aktivasi tertentu berdasarkan nilai keluaran (*output*) dari pengombinasi linier. Fungsi ini nantinya digunakan untuk menentukan keluaran (*output*) suatu neuron. Pada jaringan *backpropagation* terdapat 2 jenis fungsi aktivasi yang sering dipakai (Fausett, 1994), yaitu:

2.5.2.1 Binary Sigmoid

Sigmoid biner memiliki nilai dengan kisaran dari 0 sampai 1. Fungsi ini banyak digunakan pada jaringan syaraf yang membutuhkan nilai *output* yang bernilai pada kisaran interval 0 sampai 1. Bentuk dari *sigmoid* biner ditunjukkan pada Persamaan 2.8

$$y = f(x) = \frac{1}{1+e^{-x}} \quad (2.8)$$

Dimana:

- $y=f(x)$ = sinyal output dari x
- e^{-x} = eksponensial dari nilai -x

2.5.2.2 Bipolar Sigmoid

Sigmoid bipolar memiliki fungsi yang mirip dengan *sigmoid* biner, namun *output* dari fungsi ini berkisar antara 1 sampai -1. Bentuk dari *sigmoid* bipolar ditunjukkan pada Persamaan 2.9

$$y = f(x) = \frac{2}{1+e^{-x}} - 1 \quad (2.9)$$

Dimana:

$y=f(x)$ = sinyal output dari x

e^{-x} = eksponensial dari nilai -x

2.5.3 Tahapan Algoritma *Backpropagation*

Menurut Fausett (1994), tahapan-tahapan proses pada *Backpropagation* adalah sebagai berikut:

2.5.3.1 Inisialisasi Bobot dan Bias

Baik bobot maupun bias di inisialisasi awal secara acak dalam interval antara 0-1 atau -1

2.5.3.2 Melakukan Proses *Feed-forward*

1. Setiap *input unit* ($X_i, i=1, \dots, n$) menerima sinyal input X_i dan meneruskan sinyal tersebut pada seluruh unit pada *hidden layer*. *Input* yang digunakan adalah *input* pada data training.
2. Setiap *hidden unit* ($Z_j, j=1, \dots, p$) menjumlahkan semua sinyal *input* yang telah berbobot, berserta biasnya dengan menggunakan Persamaan 2.10

$$z_{inj} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.10)$$

Dimana:

z_{inj} = sinyal masuk lapisan tersembunyi

x_i = input yang terdiri dari neuron

v_{0j} = bias pada lapisan tersembunyi

v_{ij} = bobot pada lapisan tersembunyi

3. Menggunakan fungsi aktivasi yang telah ditentukan yaitu menggunakan *sigmoid* biner untuk menghitung sinyal *output* dari *hidden unit* dengan Persamaan 2.11, kemudian mengirim sinyal output keseluruhan unit pada unit *output*.

$$Z_j = f(z_{inj}) \quad (2.11)$$

4. Setiap unit *output* ($y_k, k = 1, \dots, m$) akan menjumlahkan sinyal-sinyal *input* yang sudah berbobot, termasuk biasnya menggunakan Persamaan 2.12

$$y_{ink} = w_{0k} + \sum_{j=1}^n z_j w_{jk} \quad (2.12)$$

Dimana:

- y_{ink} = sinyal masuk keluaran
- w_{0k} = bobot bias ke *output layer*
- z_j = hasil fungsi aktivasi *hidden layer*
- w_{jk} = bobot *hidden layer*

5. Menggunakan fungsi aktivasi yang telah ditentukan yaitu menggunakan *sigmoid* biner untuk menghitung sinyal *output* dari *hidden unit* dengan Persamaan 2.13, kemudian mengirim sinyal output keseluruhan unit pada unit *output*.

$$Y_k = f(y_{ink}) \quad (2.13)$$

2.5.3.3 Melakukan Propagasi Error (*backpropagation of error*)

1. Setiap unit output (Y_k , $k=1, \dots, m$) menerima suatu target *pattern* (*desired output*) yang sesuai dengan *input training pattern* untuk dihitung kesalahan (*error*) antara target dengan *output* yang dihasilkan jaringan menggunakan Persamaan 2.14

$$\delta_k = (t_k - y_k) y_k (1 - y_k) \quad (2.14)$$

Dimana:

- δ_k = faktor koreksi *error* lapisan keluaran
- t_k = data target
- y_k = hasil keluaran pelatihan

2. Menghitung delta perubahan bobot W_{jk} yang akan merubah bobot W_{jk} dengan Persamaan 2.15

$$\Delta W_{jk} = \alpha \delta_k z_j \quad (2.15)$$

Dimana:

- ΔW_{jk} = delta perubahan bobot lapisan keluaran
- α = *learning rate*
- δ_k = faktor koreksi *error* lapisan keluaran
- z_j = hasil fungsi aktivasi *hidden layer*

3. Menghitung delta perubahan bias W_{0k} yang akan merubah bias W_{0k} dengan Persamaan 2.16

$$\Delta W_{0k} = \alpha \delta_k \quad (2.16)$$

Dimana:

- ΔW_{0k} = delta perubahan bias lapisan keluaran
- α = *learning rate*
- δ_k = faktor koreksi *error* lapisan keluaran

4. Menghitung faktor koreksi_in unit tersembunyi

$$\delta_{inj} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.17)$$

Dimana:

- δ_{inj} = faktor koreksi_in unit tersembunyi
 δ_k = faktor koreksi *error* lapisan keluaran
 w_{jk} = bobot *hidden layer* ke *output layer*

5. Menghitung faktor koreksi bobot unit tersembunyi

$$\delta_j = \delta_{inj} z_j (1 - z_j) \quad (2.18)$$

Dimana:

- δ_j = faktor koreksi *error* lapisan tersembunyi
 δ_{inj} = faktor koreksi_in unit tersembunyi
 z_j = hasil fungsi aktivasi *hidden layer*

6. Menghitung koreksi bobot lapisan tersembunyi

$$\Delta v_{jk} = \alpha \delta_j x_j \quad (2.19)$$

Dimana:

- Δv_{jk} = delta perubahan bobot lapisan tersembunyi
 α = *learning rate*
 δ_j = faktor koreksi *error* unit tersembunyi
 x_j = nilai input

7. Menghitung koreksi bias lapisan tersembunyi

$$\Delta v_{0j} = \alpha \delta_j \quad (2.20)$$

Dimana:

- Δv_{0j} = delta perubahan bias lapisan tersembunyi
 α = *learning rate*
 δ_j = faktor koreksi *error* unit tersembunyi

2.5.3.4 Menghitung Bobot dan Bias Baru

1. Menghitung bobot baru *input layer* ke lapisan tersembunyi

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (2.21)$$

Dimana:

- $v_{ij}(\text{baru})$ = bobot baru *input layer* ke lapisan tersembunyi
 $v_{ij}(\text{lama})$ = bobot lama *input layer* ke lapisan tersembunyi
 Δv_{ij} = koreksi bobot lapisan tersembunyi

2. Menghitung bias baru *input layer* ke lapisan tersembunyi

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (2.22)$$

Dimana:

$$\begin{aligned} v_{0j}(\text{baru}) &= \text{bias baru } \textit{input layer} \text{ ke lapisan tersembunyi} \\ v_{0j}(\text{lama}) &= \text{bias lama } \textit{input layer} \text{ ke lapisan tersembunyi} \\ \Delta v_{0j} &= \text{koreksi bias lapisan tersembunyi} \end{aligned}$$

3. Menghitung bobot baru lapisan tersembunyi ke lapisan keluaran

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.23)$$

Dimana:

$$\begin{aligned} w_{jk}(\text{baru}) &= \text{bobot baru lapisan tersembunyi ke lapisan keluaran} \\ w_{jk}(\text{lama}) &= \text{bobot lama lapisan tersembunyi ke lapisan keluaran} \\ \Delta w_{jk} &= \text{koreksi bobot lapisan keluaran} \end{aligned}$$

4. Menghitung bias baru lapisan tersembunyi ke lapisan keluaran

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (2.24)$$

Dimana:

$$\begin{aligned} w_{0k}(\text{baru}) &= \text{bias baru lapisan tersembunyi ke lapisan keluaran} \\ w_{0k}(\text{lama}) &= \text{bias lama lapisan tersembunyi ke lapisan keluaran} \\ \Delta w_{0k} &= \text{koreksi bias lapisan keluaran} \end{aligned}$$

5. Menghitung MSE (*Mean Squared Error*) dan Tingkat Akurasi

Tahap perhitungan *feedforward*, *backpropagation* dan bobot serta bias baru akan diulang terus hingga kondisi berhenti terpenuhi. Kondisi penghentian yang dipakai adalah jumlah iterasi maksimum atau *error*. Proses perhitungan kesalahan dan akurasi pada *backpropagation* dapat dilakukan dengan menggunakan perhitungan MSE (Bowerman et al., 1987 dalam Sungkawa, 2011) pada Persamaan 2.25

$$MSE = \frac{1}{N} \sum_{k=1}^N (t_k - y_k)^2 \quad (2.25)$$

Dimana,

$$\begin{aligned} MSE &= \text{perhitungan kesalahan } \textit{mean squared error} \\ t_k &= \text{data target} \\ y_k &= \text{hasil keluaran pelatihan} \\ N &= \text{jumlah data} \end{aligned}$$

Pelatihan *Backpropagation* digunakan untuk mendapatkan tingkat keakuratan dari peramalan. Jika nilai asli MSE digunakan sebagai tingkat keakuratan maka keakuratan terbaik adalah nilai yang terkecil. Supaya nilai keakuratan terbaik dari *Backpropagation* tertinggi, maka digunakan Persamaan 2.26

$$\textit{Tingkat Keakuratan} = \frac{1}{1+MSE} \quad (2.26)$$