



TESIS - SM 142501

**PENERAPAN METODE EXTREME LEARNING
MACHINE UNTUK PREDIKSI TINGKAT
RISIKO WABAH DEMAM BERDARAH
BERDASARKAN KEADAAN CUACA
(STUDI KASUS : WILAYAH DKI JAKARTA)**

ABDUL MAHATIR NAJAR
NRP 0611 1650 010 012

DOSEN PEMBIMBING:
Prof. DR. Mohammad Isa Irawan, MT
DR. Dieky Adzkiya, M.Si

PROGRAM MAGISTER
DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA, KOMPUTASI DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



THESIS - SM 142501

**APPLICATION OF EXTREME LEARNING
MACHINE METHOD FOR DENGUE
OUTBREAK RISK LEVEL PREDICTION BASED
ON WEATHER CONDITION
(CASE STUDY : DKI JAKARTA REGION)**

ABDUL MAHATIR NAJAR
NRP 0611 1650 010 012

SUPERVISOR:
Prof. DR. Mohammad Isa Irawan, MT
DR. Dieky Adzkiya, M.Si

MASTER PROGRAM
DEPARTMENT OF MATHEMATICS
FACULTY OF MATHEMATICS, COMPUTING AND DATA SCIENCE
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY
SURABAYA
2018

Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si.)
di
Fakultas Matematika, Komputasi dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh:
ABDUL MAHATIR NAJAR
NRP. 0611 1650 010 012


Tanggal Ujian : 26 Juli 2018
Periode Wisuda : 118

Disetujui oleh:

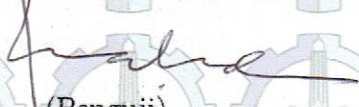
Prof. DR. Mohammad Isa Irawan, MT
NIP 19631225 198903 1 001


Pembimbing I


DR. Dieky Adzkiya, M.Si
NIP 19830517 200812 1 003


Pembimbing II

DR. Mahmud Yunus, M.Si
NIP 19620407 198703 1 005



(Penguji)

DR. Hariyanto, M.Si
NIP 19530414 198203 1 002


(Penguji)

Dekan FMKSD,




Prof. DR. Basuki Widodo, M.Sc
NIP. 19650605 198903 1 002

**PENERAPAN METODE EXTREME LEARNING MACHINE
UNTUK PREDIKSI TINGKAT RISIKO WABAH DEMAM
BERDARAH BERDASARKAN KEADAAN CUACA
(STUDI KASUS : WILAYAH DKI JAKARTA)**

Nama Mahasiswa : Abdul Mahatir Najar
NRP : 0611 1650 010 012
Pembimbing : 1. Prof. DR. Mohammad Isa Irawan, MT
2. DR. Dieky Adzkiya, M.Si

ABSTRAK

Perubahan iklim merupakan perubahan dalam distribusi kejadian cuaca terhadap kondisi rata-ratanya. Perubahan iklim baik secara langsung ataupun tidak langsung membawa dampak negatif bagi makhluk hidup di bumi. Salah satu diantaranya adalah penyakit yang disebabkan oleh vektor, seperti Demam berdarah dengue. Demam Berdarah Dengue pertama kali ditemukan di Indonesia pada tahun 1986, dimana sebanyak 58 orang di kota Surabaya terinfeksi DBD dan 24 diantaranya meninggal dunia dengan Angka Kematian (AK) mencapai 41,3%. Sejak saat itu, penyakit ini menyebar luas ke seluruh Indonesia. Hingga saat ini DBD masih menjadi salah satu masalah kesehatan yang utama di Indonesia. Penelitian ini akan memanfaatkan metode extreme learning machine (ELM) untuk meramalkan keadaan cuaca. Hasil peramalan tersebut selanjutnya digunakan sebagai prediktor untuk melakukan prediksi tingkat resiko wabah demam berdarah dengue di suatu wilayah. ELM merupakan metode pembelajaran dari jaringan saraf tiruan yang memiliki keunggulan terutama pada kecepatannya karena tidak memerlukan proses iterasi. Hasilnya menunjukkan bahwa metode ELM memberikan performa yang cukup menjanjikan. System yang dikembangkan dapat digunakan untuk melakukan prediksi tingkat resiko wabah demam berdarah beberapa bulan kedepan.

Kata-kunci: *Demam Berdarah Dengue, Extreme Learning Machine, peramalan, Perubahan Iklim, Prediksi*

**APPLICATION OF EXTREME LEARNING MACHINE
METHOD FOR DENGUE OUTBREAK RISK LEVEL
PREDICTION BASED ON WEATHER CONDITION
(CASE STUDY : DKI JAKARTA REGION)**

Name : Abdul Mahatir Najar
NRP : 0611 1650 010 012
Supervisors : 1. Prof. DR. Mohammad Isa Irawan, MT
2. DR. Dieky Adzkiya, M.Si

ABSTRACT

Climate change is a change in the distribution of weather towards the average condition. Climate change has negative impacts on living things on the earth. One of them is a disease caused by a vector, such as dengue hemorrhagic fever. Dengue Hemorrhagic Fever was discovered at Indonesia in 1986, where 58 people in Surabaya was infected by dengue and 24 of them died with mortality rate (AK) reached 41.3%. Since then, the disease is widespread throughout Indonesia. Today, Dengue Hemorrhagic Fever is still one of major health problems in Indonesia. In this research, we utilize extreme learning machine (ELM) method to forecast the weather condotion. Then, the results were used as predictor to predict dengue hemorrhagic fever risk level in a region. ELM is a learning method of artificial neural networks that has an advantage especially at its speed because it does not require iteration process. The results show that ELM give a promising performance. System developed can be used to predict the DHF risk level for the next month.

Key-words: *Dengue, Extreme Learning Machine, Climate Change, Forecasting, Prediction*

KATA PENGANTAR

Segala puji bagi Allah SWT yang telah melimpahkan rahmat, taufik, dan hidayah-Nya, sehingga penulis dapat menyelesaikan dengan lancar Tesis yang berjudul

PENERAPAN METODE EXTREME LEARNING MACHINE UNTUK PREDIKSI TINGKAT RISIKO WABAH DEMAM BERDARAH DENGUE BERDASARKAN KEADAAN CUACA (STUDI KASUS : WILAYAH DKI JAKARTA)

Tesis ini dibuat untuk memenuhi salah satu syarat dalam memperoleh gelar Magister Program Strata-2 Departemen Matematika, Fakultas Matematika, Komputasi dan Sains Data, Institut Teknologi Sepuluh Nopember.

Penyusunan Tesis ini tidak terlepas dari bantuan berbagai pihak. oleh karena itu, pada kesempatan ini, penulis menyampaikan terima kasih kepada pihak-pihak tersebut diantaranya:

1. Rektor Institut Teknologi Sepuluh Nopember
2. Dekan Fakultas Matematika, Komputasi dan Sains Data, Institut Teknologi Sepuluh Nopember
3. Kepala Departemen Matematika, Fakultas Matematika, Komputasi dan Sains Data, Institut Teknologi Sepuluh Nopember
4. Kepala Program Studi Strata-2 Departemen Matematika, Fakultas Matematika, Komputasi dan Sains Data, Institut Teknologi Sepuluh Nopember
5. Bapak Prof. Dr. Isa Irawan, MT selaku Dosen Pembimbing I dalam penyelesaian Tesis
6. Bapak Dr. Dieky Adzkiya, M.Si selaku Dosen Pembimbing II dalam penyelesaian Tesis
7. Ibu Prof. Dr. Erna Apriliani, M.Si., Bapak Dr. Hariyanto, M.Si. dan Bapak Dr. Mahmud Yunus, M.Si. selaku Dosen Penguji dalam penyelesaian Tesis ini.
8. Ibu Dr. Mardlijah, MT. selaku Dosen Wali selama menempuh program studi Strata-2
9. Orang tua, kakak, dan adik yang selalu memberikan do'a serta dukungan selama menempuh program studi Strata-2

10. Teman-teman seperjuangan di Program Studi Magister Matematika. Terimakasih banyak atas semangat yang menginspirasi, dan bantuan sharing ilmu dalam diskusi, sehingga selama perkuliahan sampai Tesis ini selesai dapat berjalan dengan lancar
11. Staff Pasca Sarjana Matematika, Mbak Resty dan Mas Afif. Terimakasih banyak atas bantuan dalam menginformasikan keperluan administrasi dan bersedia menampung keluh kesah penulis selama proses penyelesaian Tesis hingga kelulusan
12. Kakak dan Adik angkatan di Program Studi Magister Matematika, serta semua pihak yang telah memberikan do'a dan dukungannya kepada penulis, yang tidak dapat penulis sebutkan satu-persatu.

Penulis sangat terbuka menerima saran dan ide demi kesempurnaan penulisan selanjutnya. Penulis berharap semoga Tesis ini dapat bermanfaat bagi pembaca, dan semua yang telah dikerjakan ini mendapat ridho dari Allah SWT.

Surabaya, Agustus 2018

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI	7
2.1 Penelitian-Penelitian Terkait	7
2.2 Demam Berdarah Dengue dan Cuaca	8
2.3 Jaringan Syaraf Tiruan	9
2.3.1 Fungsi Aktivasi	11
2.3.2 Normalisasi dan Denormalisasi	12
2.3.3 Extreme Learning Machine	13
2.4 Evaluasi Kinerja Model	15
BAB 3 METODE PENELITIAN	17
3.1 Tahapan Penelitian	17
3.1.1 Tahap Inisiasi	17
3.1.2 Tahap Persiapan dan Perancangan Model	18
3.1.3 Tahap Prediksi dan Analisa	19
3.1.4 Penarikan Kesimpulan	20
3.1.5 Penyusunan Laporan	20
3.2 Tempat Penelitian	20
BAB 4 Hasil dan Pembahasan	21
4.1 Perancangan Data	21
4.1.1 <i>Preprocessing</i> Data	24
4.2 Perancangan dan Pelatihan Model Jaringan Syaraf Tiruan	25

4.2.1	Klasifikasi Tingkat Risiko Wabah Demam Berdarah Berdasarkan Keadaan Cuaca	25
4.2.2	Peramalan Keadaan Cuaca	31
4.2.3	Prediksi Tingkat risiko wabah DBD berdasarkan Cuaca	37
BAB 5	KESIMPULAN DAN SARAN	41
5.1	Kesimpulan	41
5.2	Saran	42
	DAFTAR PUSTAKA	43

DAFTAR GAMBAR

Gambar 1.1	Angka Insiden (AI) demam berdarah 2011-2016	3
Gambar 2.1	Arsitektur Jaringan Syaraf Tiruan	10
Gambar 3.1	Metode Pengerjaan Penelitian	17
Gambar 3.2	Tahapan Persiapan dan Perancangan Model	19
Gambar 4.1	Angka Insiden Demam Berdarah DKI Jakarta Tahun 2008 - 2016	23
Gambar 4.2	<i>Pseudocode</i> untuk normalisasi data	25
Gambar 4.3	<i>Pseudocode</i> untuk mengukur performa model jaringan	29
Gambar 4.4	Performa Jaringan ELM berdasarkan Fungsi Aktivasi dan Banyaknya <i>Hidden Neuron</i>	30
Gambar 4.5	Model Terbaik Jaringan ELM Untuk Klasifikasi Tingkat Risiko Wabah Demam Berdarah Berdasarkan Keadaan Cuaca	31
Gambar 4.6	Pembentukan Dataset Peramalan Temperatur Maksimum	34
Gambar 4.7	Performa model jaringan ELM untuk peramalan keadaan temperatur maksimum	36
Gambar 4.8	Model Terbaik Jaringan ELM Untuk Peramalan Cuaca	37

DAFTAR TABEL

Tabel 4.1	Banyaknya Kasus DBD di DKI Jakarta	22
Tabel 4.2	Koefisien relasi variabel cuaca dan insiden demam berdarah	24
Tabel 4.3	Rancangan Model jaringan	26
Tabel 4.4	Hasil klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca	32
Tabel 4.5	Rancangan Model Jaringan untuk Peramalan Keadaan Cuaca	33
Tabel 4.6	Keadaan cuaca tahun Januari 2005 - Desember 2016	33
Tabel 4.7	Dataset Peramalan Temperatur Maksimum dengan 6 Neuron Input	34
Tabel 4.8	Performa jaringan ELM untuk peramalan keadaan cuaca .	35
Tabel 4.9	Hasil Peramalan Keadaan Cuaca	38
Tabel 4.10	Hasil Prediksi Tingkat Resiko Wabah Demam Berdarah Tahun 2017	38

BAB 1

PENDAHULUAN

Pada bab ini, dijelaskan mengenai hal-hal yang menjadi latar belakang penelitian. Selain itu, dirumuskan masalah-masalah yang berkaitan tentang topik penelitian beserta batasan-batasan masalahnya. Pada bab ini, ditunjukkan pula tujuan dan manfaat dari penyusunan penelitian.

1.1 Latar Belakang

Cuaca adalah keadaan dinamika udara di atmosfer pada waktu dan tempat tertentu. Sedangkan Iklim adalah kebiasaan cuaca yang terjadi di suatu tempat atau daerah. Definisi lain, iklim merupakan karakter kecuaan suatu wilayah. Perubahan iklim merupakan perubahan dalam kondisi cuaca rata-rata atau perubahan dalam distribusi kejadian cuaca terhadap kondisi rata-ratanya. Temperatur, tekanan atmosfer, angin, kelembaban, dan curah hujan adalah parameter-parameter dari cuaca yang bersama-sama dapat menjelaskan kondisi iklim suatu daerah di setiap periode (Aldrian E., dkk, 2011). Secara umum temperatur rata-rata di wilayah Indonesia akan mengalami kenaikan sebesar $0.5 - 3.92\text{ }^{\circ}\text{C}$ pada tahun 2100 dari kondisi baseline 1981-2010, sedangkan suhu udara minimum akan mengalami peningkatan sebesar $0.04 - 0.07\text{ }^{\circ}\text{C}$. Selain itu, berdasarkan data pengamatan telah terjadi pergeseran bulan basah dan kering. Intensitas curah hujan yang lebih tinggi dan durasi hujan yang lebih pendek terjadi di Sumatra bagian utara dan Kalimantan, sedangkan curah hujan rendah dan durasi hujan lebih panjang terjadi di bagian selatan Jawa dan Bali. Kejadian banjir rob sudah lebih sering dialami masyarakat kota yang berlokasi di pinggir laut. Gelombang panas (El Nino) yang menyebabkan kebakaran gambut dan gelombang basah (La Nina) yang menyebabkan banjir sudah mengalami perubahan masa terjadinya. Cuaca ekstrim juga lebih banyak terjadi di Indonesia dan tentu saja mengganggu kegiatan ekonomi (Dirjen Pengendalian Perubahan Iklim KLHK, 2016).

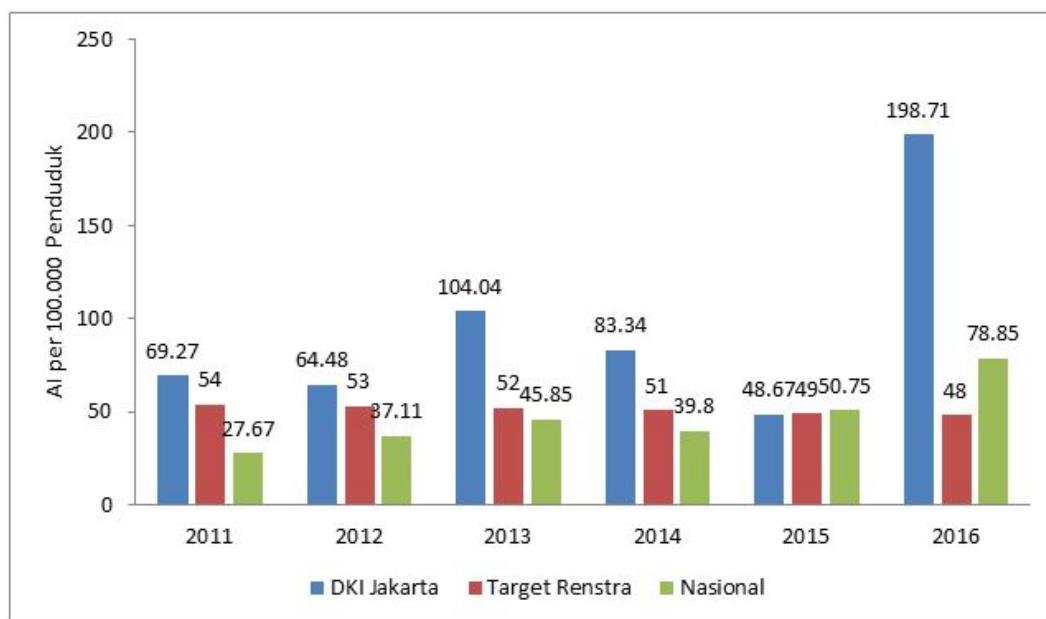
Menurut McMichael (2003) perubahan iklim secara tidak langsung juga akan mempengaruhi transmisi banyak penyakit menular terutama

penyakit yang disebabkan oleh vektor atau lebih dikenal dengan istilah *vector borne disease*. Hal ini disebabkan karena mekanisme penyakit menular sangat ditentukan oleh interaksi antara *Host-Agent-Environment*. Misalnya seperti dalam (Fitriyani, 2007), bahwa curah hujan yang tinggi membuat sejumlah daerah rawan terjadi genangan air. Sedangkan genangan air ini merupakan tempat yang sangat ideal untuk berkembangnya jentik nyamuk penyebab demam berdarah dengue.

Demam berdarah dengue (DBD) banyak ditemukan di daerah tropis dan sub-tropis. Data dari seluruh dunia menunjukkan Asia menempati urutan pertama dalam jumlah penderita DBD setiap tahunnya. Sementara itu, terhitung sejak tahun 1968 hingga tahun 2009, World Health Organization (WHO) mencatat negara Indonesia sebagai negara dengan kasus DBD tertinggi di Asia Tenggara (Kemenkes RI, 2010). Demam berdarah dengue pertama kali ditemukan di Indonesia pada tahun 1986, dimana sebanyak 58 orang di kota Surabaya terinfeksi DBD dan 24 diantaranya meninggal dunia dengan Angka Kematian (AK) mencapai 41,3%. Sejak saat itu, penyakit ini menyebar luas ke seluruh Indonesia. Hingga saat ini DBD masih menjadi salah satu masalah kesehatan yang utama di Indonesia (Kemenkes RI, 2011-2016). Seiring meningkatnya mobilitas dan kepadatan penduduk, perubahan iklim serta faktor epidemiologi lainnya, jumlah penderita dan luas daerahnya juga semakin bertambah. Pada tahun 2015, tercatat terdapat sebanyak 126.675 penderita DBD di 34 Provinsi di Indonesia dan 1.229 orang diantaranya meninggal dunia. Jumlah tersebut meningkat dari tahun sebelumnya, yakni sebanyak 100.347 penderita DBD dan sebanyak 907 penderita meninggal dunia (Kemenkes RI, 2016b).

Sebagai ibu kota negara, sekaligus daerah dengan kepadatan penduduk paling tinggi di Indonesia DKI Jakarta menjadi rentan dengan berbagai penyakit, salah satunya adalah demam berdarah. Gambar 1.1 menunjukkan angka insiden (AI) demam berdarah di DKI Jakarta dari tahun 2011 hingga 2016 yang dibandingkan dengan angka insiden nasional. Berdasarkan Gambar 1.1 terlihat bahwa selain tahun 2015 DKI Jakarta memiliki angka insiden demam berdarah dengue yang lebih tinggi dari target resntra serta angka insiden nasional. Hal ini menunjukkan bahwa DKI Jakarta termasuk daerah dengan risiko tinggi DBD.

Pada tahun 2016 Pusat data Kementerian Kesehatan RI melakukan analisis iklim dan pengaruhnya terhadap DBD di Provinsi Bali dan Kalimantan Timur. Data yang digunakan adalah data sekunder dalam rentang 2010–2015.



Gambar 1.1: Angka Insiden (AI) demam berdarah 2011-2016
 Sumber : Profil Kesehatan Indonesia 2011-2016

Hasil analisis ini menunjukkan bahwa pengaruh iklim terhadap kejadian DBD di Provinsi Bali adalah sebesar 76,8% (Kemenkes RI, 2016b).

Penelitian yang dilakukan oleh Banu dkk (2014) juga mendukung teori bahwa iklim merupakan salah satu faktor utama terjadinya wabah demam berdarah. Perubahan iklim menyebabkan perubahan curah hujan, temperatur, dan kelembapan. Hal ini berdampak pada perkembangbiakan vektor penyakit nyamuk penyebab demam berdarah. Dengan kata lain jika dapat melakukan prediksi terhadap perubahan cuaca yang notabene adalah keadaan iklim dalam waktu lebih singkat maka kejadian demam berdarah juga dapat diprediksi. Prediksi terhadap kejadian demam berdarah dapat menjadi informasi penting bagi pengambil kebijakan guna melakukan langkah-langkah antisipasi agar meminimalisir kerugian.

Banyak metode yang telah dikembangkan untuk mendapatkan hasil prediksi yang baik. Salah satu metode yang sering digunakan adalah jaringan syaraf tiruan (JST). JST merupakan sebuah metode dalam dunia komputer yang mengadopsi sistem pemrosesan informasi pada sistem syaraf biologis yang ada pada manusia. Banyak penelitian menyimpulkan bahwa metode JST lebih baik daripada metode-metode peramalan/prediksi konvensional (Pangaribuan, 2016). Dalam (Huang dkk, 2006) dikemukakan bahwa salah satu metode yang merupakan pengembangan dari Metode JST *feed-forward* dengan satu *hidden*

layer adalah *Extreme Learning Machine* (ELM). Metode ini dikembangkan untuk mengatasi kelemahan dari metode-metode JST sebelumnya dalam hal *learning speed*. Kelemahan ini disebabkan karena semua bobot *input* dan bias pada jaringan ditentukan secara iteratif. Pada metode ELM, bobot *input* dan bias mula-mula ditentukan secara random. Setelah itu, bobot akhir dicari menggunakan *Moore-Penrose Generalized Invers*. Hal ini menyebabkan ELM memiliki *learning speed* yang lebih cepat.

Berdasarkan latar belakang diatas, maka dalam penelitian ini akan dikaji penggunaan metode *extreme learning machine* untuk melakukan prediksi terkait tingkat risiko terjadinya wabah demam berdarah di DKI Jakarta berdasarkan keadaan cuaca. Untuk dapat melakukan prediksi ini, selain peramalan cuaca terlebih dahulu juga harus dibangun model jaringan ELM untuk klasifikasi tingkat risiko demam berdarah berdasarkan keadaan cuaca.

1.2 Rumusan Masalah

Rumusan masalah yang menjadi fokus utama dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membangun model jaringan syaraf tiruan *Extreme Learning Machine* untuk klasifikasi tingkat risiko demam berdarah dengue berdasarkan keadaan cuaca ?
2. Bagaimana membangun model jaringan syaraf tiruan *Extreme Learning Machine* untuk peramalan cuaca ?
3. Bagaimana menerapkan model jaringan syaraf tiruan *Extreme Learning Machine* yang telah dibangun untuk prediksi tingkat risiko wabah demam berdarah dengue ?

1.3 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Data yang digunakan adalah data sekunder, yaitu data kasus demam berdarah dengue yang dieporleh dari dinas kesehatan DKI Jakarta serta keadaan cuaca di DKI Jakarta yang diperoleh dari BPS DKI Jakarta.
2. Variabel yang digunakan adalah temperatur, kelembaban, curah hujan serta Angka Insiden kejadian demam berdarah dengue.

3. Pada Penelitian ini tidak dibahas masalah vektor pembawa penyakit maupun faktor lain yang mempengaruhi tingkat risiko wabah demam berdarah selain keadaan cuaca.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Memperoleh model jaringan syaraf tiruan *Extreme Learning Machine* untuk klasifikasi tingkat risiko wabah demam berdarah berdasarkan keadaan cuaca.
2. Memperoleh model jaringan syaraf tiruan *Extreme Learning Machine* untuk peramalan cuaca.
3. Menerapkan model jaringan *Extreme Learning Machine* yang telah diperoleh untuk prediksi tingkat risiko demam berdarah dengue berdasarkan keadaan cuaca.

1.5 Manfaat Penelitian

Melalui penelitian ini diharapkan dapat memberi manfaat yaitu:

1. Memberikan kontribusi pengetahuan mengenai penerapan metode *Extreme Learning Machine* untuk prediksi wabah demam berdarah dengue.
2. Menjadi salah satu alat bantu bagi pengambil kebijakan dalam mempersiapkan langkah antisipasi guna meminimalisir dampak buruk yang ditimbulkan oleh demam berdarah dengue.

BAB 2

KAJIAN PUSTAKA DAN DASAR TEORI

Pada bab ini, dipaparkan mengenai penelitian-penelitian terdahulu yang berkaitan dengan topik penelitian. Selain itu, ditunjukkan beberapa teori-teori yang menjadi landasan penyelesaian masalah yang dikemukakan pada penelitian ini.

2.1 Penelitian-Penelitian Terkait

Pada sub bab ini, dipaparkan mengenai penelitian-penelitian yang berkaitan dengan topik penelitian. Penelitian-penelitian tersebut diantaranya berkaitan dengan metode *extreme learning machine* untuk peramalan serta hubungan antara cuaca dan kejadian demam berdarah.

- (a). Pada penelitian yang dilakukan oleh Sintorini (2007) dalam makalah yang berjudul "*Pengaruh Iklim terhadap Kasus Demam Berdarah Dengue*", telah dilakukan analisis ekologi untuk mengetahui dinamika kejadian DBD dalam kaitannya dengan pola variabilitas iklim di Jakarta. Disimpulkan bahwa selain pengetahuan masyarakat yang rendah, faktor iklim juga berpengaruh pada kejadian DBD. Faktor iklim yang paling berpengaruh pada kasus DBD adalah curah hujan, temperatur dan kelembaban.
- (b). Pada penilitan yang dilakukan oleh Banu dkk (2014) dalam makalah yang berjudul "*Projecting the Impact of Climate Change on Dengue Transmission in Dhaka, Bangladesh*", telah dilakukan analisis terhadap dampak variabel cuaca terbadap penyebaran DBD di kota Dhaka, Banglades kemudian diperkirakan proyeksi risiko terjadinya DBD berdasarkan perubahan iklim. Peneleitian ini menggunakan 3 variabel cuaca yaitu suhu, curah hujan dan kelembaban. Hasilnya ditunjukkan bahwa suhu maksimum dan kelembaban adalah variabel cuaca yang paling berpengaruh dengan penyebaran penyakit DBD. Dalam kesimpulan penelitian ini juga diungkapkan bahwa dengan asumsi bahwa pada tahun 2100 teradi peningkatan suhu sebesar 3.3°C

sebagaimana yang diproyeksikan oleh IPCC maka secara substansial akan meningkatkan kejadian demam berdarah di Dhaka.

- (c). Pada penelitian yang dilakukan oleh Apriliana (2017) dalam makalah yang berjudul "*Pengaruh Iklim Terhadap Kejadian Demam Berdarah Dengue di Kota Bandar Lampung, Provinsi Lampung*", telah dilakukan penelitian terhadap pengaruh iklim terhadap kasus demam berdarah menggunakan pendekatan studi kohort retrospektif. Hasilnya penelitian ini menyimpulkan bahwa pada setiap musim terdapat perbedaan unsur iklim yang berpengaruh terhadap kejadian DBD di Kota Bandar Lampung. Pada musim kemarau, unsur iklim yang berpengaruh terhadap kejadian DBD adalah kelembaban udara, sedangkan pada musim hujan periode November – Desember, unsur iklim yang berpengaruh adalah curah hujan.
- (d). Pada penelitian yang dilakukan oleh Huang dkk (2004) dalam makalah yang berjudul "*Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks*", telah dikembangkan sebuah algoritma baru guna mengatasi kelemahan dari *single layer feedforward neural networks*(SLFNs) yang kemudian disebut *extreme learning machine*(ELM). Pada penelitian ini menunjukkan bahwa algoritma ini memberikan *generalization performance* yang lebih baik dan *learning speed* yang jauh lebih cepat.
- (e). Pada penelitian yang dilakukan oleh Asyima dan Aggarwal (2016) dalam makalah yang berjudul "*Wind Power Forecasting Using Extreme Learning Machine*", metode *Extreme Learning Machine* (ELM) telah berhasil diterapkan untuk melakukan peramalan tenaga angin yang kemudian dapat dimanfaatkan pada pembangkit listrik tenaga angin.

2.2 Demam Berdarah Dengue dan Cuaca

Demam Berdarah Dengue (DBD) adalah penyakit infeksi virus akut yang disebabkan oleh virus dengue yang tergolong *Arthropod-Borne*, genus *flavivirus*, family *flaviviridae*. DBD ditularkan melalui gigitan nyamuk terutama *aedes spp*, *aedes aegypti*, dan *aedes albopictus*. Nyamuk-nyamuk jenis tersebut banyak tersebar di daerah tropis dan subtropis termasuk diantaranya Indonesia (Kemenkes RI, 2011-2016).

Salah satu pemicu meledaknya insiden penyakit DBD adalah Perubahan iklim/cuaca, dimana perubahan tersebut menyebabkan perubahan

curah hujan, hari hujan, temperatur, dan kelembaban, sehingga berefek terhadap ekosistem daratan dan lautan. Selain itu perubahan tersebut berpengaruh terhadap kesehatan terutama terhadap perkembangbiakan vektor penyakit seperti nyamuk *Aedes*, malaria, dan lainnya. (Apriliana, 2017).

Cuaca adalah keadaan udara di suatu tempat (Hasanah, 2007), cuaca juga dapat didefinisikan sebagai keadaan iklim disuatu wilayah dalam rentang waktu yang lebih singkat. Perubahan iklim/cuaca seperti perubahan curah hujan dan suhu mempengaruhi organisme vektor DBD yaitu terjadinya perubahan dalam pergerakan, pengembangbiakan dan tingkah laku, serta mempengaruhi kecepatan kematangan dan lamanya hidup vektor penginfeksi.

Beberapa penelitian menunjukkan bahwa ada korelasi positif antara variabel cuaca terhadap distribusi dan populasi vektor serta peningkatan kasus DBD. Pada musim kemarau, unsur iklim yang berpengaruh terhadap kejadian DBD di Kota Bandar Lampung adalah kelembaban udara, sedangkan pada musim hujan periode November – Desember, unsur iklim yang berpengaruh adalah curah hujan (Apriliana, 2017). Suhu maksimum dan kelembaban adalah variabel cuaca yang paling berpengaruh dengan penyebaran penyakit DBD di Dhaka, Bangladesh (Banu, dkk, 2014).

Tingkat risiko kejadian demam berdarah di suatu wilayah dapat diukur berdasarkan angka insiden (AI). Angka insiden adalah jumlah kasus baru penyakit tertentu yang dilaporkan pada periode waktu dan tempat tertentu dibagi dengan jumlah penduduk dimana penyakit tersebut berjangkit. Untuk kasus demam berdarah, suatu daerah dapat dikategorikan termasuk dalam risiko tinggi, sedang dan rendah yaitu risiko tinggi bila $AI > 55$ per 100.000 penduduk, risiko sedang bila $AI 20-55$ per 100.000 penduduk dan risiko rendah bila $AI < 20$ per 100.000 penduduk (Kemenkes RI, 2016b). AI dapat diperoleh menggunakan rumus berikut:


$$AI = \frac{JK \times 100.000}{JP} \quad (2.1)$$

dimana JK adalah jumlah kasus di suatu wilayah dan JP adalah jumlah penduduk di wilayah tersebut.

2.3 Jaringan Syaraf Tiruan

Jaringan Syaraf tiruan yang biasanya disingkat JST, adalah model matematika atau model komputasi yang diinspirasi oleh struktur fungsional dari jaringan Syaraf biologi (Irawan, 2015). Pengembangan model dilakukan

dengan menentukan hubungan antar neuron-neuron. Pola hubungan ini berkaitan erat dengan hubungan antar *layer*. Setiap *layer* terdiri dari sekumpulan neuron. Selain itu juga ada *hidden layer* yang terdiri dari neuron tersembunyi. Arsitektur jaringan Syaraf tiruan dapat dilihat pada Gambar 2.1.



Gambar 2.1: Arsitektur Jaringan Syaraf Tiruan

1. *Input Layer*

Input layer menerima masukan dari luar jaringan Syaraf. Aktivasi dari neuron-neuron lapisan ini menunjukkan informasi dasar yang kemudian digunakan dalam jaringan Syaraf tiruan.

2. *Hidden Layer*

Hidden Layer menerima dan mengirim sinyal ke jaringan Syaraf. Aktifasi setiap neuron *hidden layer* ditentukan oleh aktivasi dari neuron-neuron masukan dan bobot dari koneksi antar neuron-neuron masukan dan neuron-neuron pada *hidden layer*.

3. *Output Layer*

Output layer mengirim data ke jaringan Syaraf dan menghasilkan nilai output. Nilai output ini biasanya berupa nilai diskrit yang merupakan hasil pengolahan dari data masukan.

Secara matematis model jaringan Syaraf seperti yang diilustrasikan pada Gambar 2.1 dapat dituliskan sebagai berikut (Fauset, 1994):

$$Z_j = g(X_1w_{1j} + \dots + X_nw_{nj}) \tag{2.2}$$

$$Y = g(Z_1\beta_1 + \dots + Z_p\beta_p + \dots + Z_j\beta_j) \quad (2.3)$$

dimana Z_j adalah nilai neuron-neuron pada *hidden layer* yang telah dikenakan fungsi aktivasi, dan Y adalah nilai neuron-neuron pada *output layer* yang telah dikenakan fungsi aktivasi.

2.3.1 Fungsi Aktivasi

Salah satu operasi dasar dalam jaringan syaraf tiruan adalah aktivasi. Secara umum ada beberapa fungsi aktivasi yang sering digunakan (Kusumadewi, S., 2004):

1. Fungsi Linear (Identitas)

Fungsi linear memiliki nilai output yang sama dengan nilai inputnya. Fungsi linear dirumuskan sebagai berikut:

$$g(x) = x \quad (2.4)$$

2. Fungsi Undak Biner (*Step Function*)

Untuk mengkonversikan input dari nilai suatu variabel ke suatu output biner, jaringan dengan lapisan tunggal sering menggunakan fungsi undak biner (*step function*). Fungsi undak biner dirumuskan sebagai berikut:

$$g(x) = \begin{cases} 0, & \text{jika } x < 0 \\ 1, & \text{jika } x \geq 0 \end{cases} \quad (2.5)$$

3. Fungsi Bipolar

Pada dasarnya fungsi bipolar mirip dengan fungsi undak biner, hanya saja output yang dihasilkan berupa 1 atau -1. Fungsi bipolar dirumuskan sebagai berikut:

$$g(x) = \begin{cases} 1, & \text{jika } x \geq 0 \\ -1, & \text{jika } x < 0 \end{cases} \quad (2.6)$$

4. Fungsi Sigmoid Biner

Fungsi sigmoid biner pada jaringan syaraf tiruan yang membutuhkan nilai output yang terletak pada interval 0 sampai 1. Fungsi sigmoid biner dirumuskan sebagai berikut:

$$g(x) = \frac{1}{1 + e^{-\sigma x}} \quad (2.7)$$

5. Fungsi Sigmoid Bipolar

Pada dasarnya fungsi sigmoid bipolar mirip dengan fungsi sigmoid biner, hanya saja output yang dihasilkan berupa 1 atau -1. Fungsi sigmoid bipolar dirumuskan sebagai berikut: sebgai berikut:

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

2.3.2 Normalisasi dan Denormalisasi

Dalam proses penerapan jaringan syaraf tiruan, sering kali data set yang tersedia tidak dapat langsung diproses. Perlu dilakukan normalisasi, penskalaan atau transformasi pada data yang ada sebelum dapat diproses dalam jaringan syaraf tiruan.

- Normalisasi

Kebanyakan Jaringan syaraf tiruan dan dan kecerdasan buatan lainnya, memerlukan data ditransformasi ke skala tertentu sebelum diproses lebih lanjut. Biasanya dataset akan ditransformasi ke dalam rentang 0 hingga 1 atau -1 hingga 1. Proses transformasi ini sering juga disebut dengan istilah normalisasi. Setiap data harus ditransformasi ke dalam rentang yang sama. Untuk melakukan transformasi dataset, dapat digunakan persamaan 2.9 berikut (Eberhart R.C., dan Shi, Y, 2007) :

$$A'_{ki} = \frac{(A_{ki} - A_{kmin})(Hi - Lo)}{(A_{kmax} - A_{kmin})} + Lo \quad (2.9)$$

Dimana, A'_{ki} adalah data ke-i dari vektor input yang telah ditransformasi ke rentang yang diinginkan; A_{ki} adalah data ke-i dari vektor input sebelum ditransformasi; A_{kmax} adalah nilai maksimum dari data sebelum ditransformasi; A_{kmin} adalah nilai minimum dari data sebelum ditransformasi; $(A_{kmax} - A_{kmin})$ adalah pembagi, yang menormalisasi data sebenarnya (sebelum transformasi) ke dalam rentang 0-1; Hi adalah batas atas dari rentang yang diharapkan setelah normalisasi; Lo adalah batas bawah dari rentang yang diharapkan setelah normalisasi; dan $(Hi - Lo)$ adalah faktor penskalaan yang memetakan nilai-nilai pada vektor input ke rentang yang diharapkan.

- Denormalisasi

Denormalisasi merupakan kebalikan dari proses normalisasi. Jika pada proses normalisasi data yang ada (data sebenarnya) ditransformasi ke

dalam rentang tertentu, maka proses denormalisasi adalah proses yang menghasilkan output berupa data *real-world*. Dengan kata lain, proses denormalisasi mentransformasi kembali nilai yang jaringan syaraf tiruan ke domain aslinya. Denormalisasi dapat dilakukan dengan persamaan 2.10 berikut (Eberhart R.C., dan Shi, Y, 2007) :

$$C'_{ki} = \frac{(C_{ki} - Lo)(C_{kmax} - C_{kmin})}{(Hi - Lo)} + C_{kmin} \quad (2.10)$$

Dimana C'_{ki} adalah elemen ke-i dari vektor output sebenarnya (data *real-world*); C_{ki} adalah elemen ke-i dari vektor output jaringan (belum didenormalisasi) ; Lo adalah nilai aktivasi jaringan minimum; Hi adalah nilai aktivasi jaringan maksimum; C_{kmax} adalah batas atas domain output; C_{kmin} adalah batas bawah domain output; dan $(C_{kmax} - C_{kmin})$ adalah faktor skala yang memetakan output dari jaringan ke domain data sebenarnya.

2.3.3 Extreme Learning Machine

Extreme learning machine (ELM) merupakan metode pembelajaran baru dari jaringan saraf tiruan. Metode ini pertama kali diperkenalkan oleh Huang (2004). Sebagai suatu jaringan saraf tiruan *feedforward* dengan hidden layer tunggal (SLFNs), Metode ELM memiliki beberapa kelebihan dibandingkan dengan metode SLFNs terdahulu yaitu :

1. ELM memiliki kecepatan belajar yang jauh lebih baik. Hal ini dikarenakan dalam prosesnya tidak diperlukan iterasi sebagaimana yang diperlukan dalam metode SLFNs konvensional.
2. Tidak seperti SLFNs konvensional yang mudah terjebak pada minima lokal, ELM memiliki kinerja generalisasi yang lebih baik.
3. Pada metode ELM dapat digunakan fungsi aktivasi yang tidak terdiferensiasi.

Metode ELM mempunyai model matematis yang berbeda dari jaringan syaraf tiruan *feedforward*. Model matematis dari ELM lebih sederhana dan efektif. Untuk N jumlah sampel yang berbeda (x_i, y_i) , dimana $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ dan $y_i = [y_{i1}, y_{i2}, \dots, y_{in}]^T \in R^m$, SLFNs standar dengan jumlah layer tersmbunyi sebanyak \tilde{N} dengan fungsi aktifasi $g(x)$ secara matematis dapat

dimodelkan sebagai berikut (Huang dkk, 2006):

$$\sum_{j=1}^{\tilde{N}} \beta_j g(w_j \cdot x_i + b_j) = o_i, \quad i = 1, \dots, N, \quad (2.11)$$

dimana $w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T$ adalah matriks bobot yang menghubungkan antara neuron input dan neuron pada layar tersembunyi, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T$ adalah vektor bobot yang menghubungkan neuron pada layar tersembunyi dengan neuron output dan b_j adalah *bias* dari neuron pada layar tersembunyi. $w_j \cdot x_i$ merupakan hasil kali dalam w_j dan x_i . Dengan asumsi bahwa error yang diharapkan adalah 0 maka ini berarti $\sum_{i=1}^N \|o_i - y_i\| = 0$, sehingga persamaan 2.11 menjadi:

$$\sum_{j=1}^{\tilde{N}} \beta_j g(w_j \cdot x_i + b_j) = y_j, \quad i = 1, \dots, N, \quad (2.12)$$

Selanjutnya persamaan 2.12 dapat dapat dituliskan dalam bentuk:

$$H\beta = Y, \quad (2.13)$$

dimana

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \cdots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix} \quad (2.14)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_{\tilde{N}} \end{bmatrix}_{\tilde{N} \times m} \quad \text{dan} \quad Y = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}_{N \times m} \quad (2.15)$$

Dalam Huang (2006), H disebut matriks *hidden layer output* dari jaringan saraf tiruan, dimana kolom ke- i dari matriks H adalah output dari neuron pada layar tersembunyi yang bersesuaian dengan x_1, x_2, \dots, x_N .

Pada aplikasinya proses pelatihan pada metode ELM bertujuan untuk mencari nilai bobot β . Dengan memodifikasi persamaan 2.13 maka nilai β

dapat diperoleh.

$$\beta = H^+Y \quad (2.16)$$

dimana H^+ adalah *Moore-Penrose Generalized inverse* dari matriks H . Berdasarkan teori tersebut kemudian disusun algoritma ELM sebagai berikut: Diberikan sebuah *training set* $\mathcal{N} = \{(x_i, y_i) | x_i \in R^n, y_i \in R^m, i = 1 \dots N\}$ fungsi aktivasi $g(x)$ dan neuron pada layer tersembunyi sebanyak \tilde{N} .

Step 1 : Inisiasi bobot w_i dan bias b_i secara random dimana $i = 1, \dots, \tilde{N}$

Step 2 : Hitung matriks *Hidden layer output* \mathbf{H}

Step 3 : hitung bobot output β

$$\beta = H^+Y$$

dimana $Y = [y_1, \dots, y_N]^T$

2.4 Evaluasi Kinerja Model

Setelah mendapatkan hasil prediksi melalui proses yang sebelumnya dijalankan, hal yang dilakukan selanjutnya adalah melakukan evaluasi kinerja prediksi. Seperti yang diketahui masa depan adalah hal yang tidak bisa ketahu secara pasti, namun dengan melakukan peramalan atau prediksi, masa depan akan diketahui hingga mendekati realita. Hasil peramalan tidak ada yang dapat dipastikan benar seluruhnya, akan ada penyimpangan nilai atau perbedaan nilai dengan kenyataan. Untuk itu berikut adalah evaluasi kinerja yang dilakukan untuk mengetahui seberapa benarkah prediksi atau seberapa kecil penyimpangan yang dialami (Rofiq, 2017).

1. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan rata-rata selisih antara data aktual dan data hasil perhitungan. Secara matematis dituliskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^x |O_i - P_i| \quad (2.17)$$

2. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata

kesalahan persentase absolut tersebut. MAPE mengindikasikan seberapa besar kesalahan prediksi yang dibandingkan dengan nilai nyata.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{P_i} \right| \times 100\% \quad (2.18)$$

3. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) dihitung dengan mengkuadratkan error (*predicted - observed*) dibagi dengan jumlah data (rata-rata), lalu diakarkan. Secara matematis, rumusnya ditulis sebagai berikut

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (2.19)$$

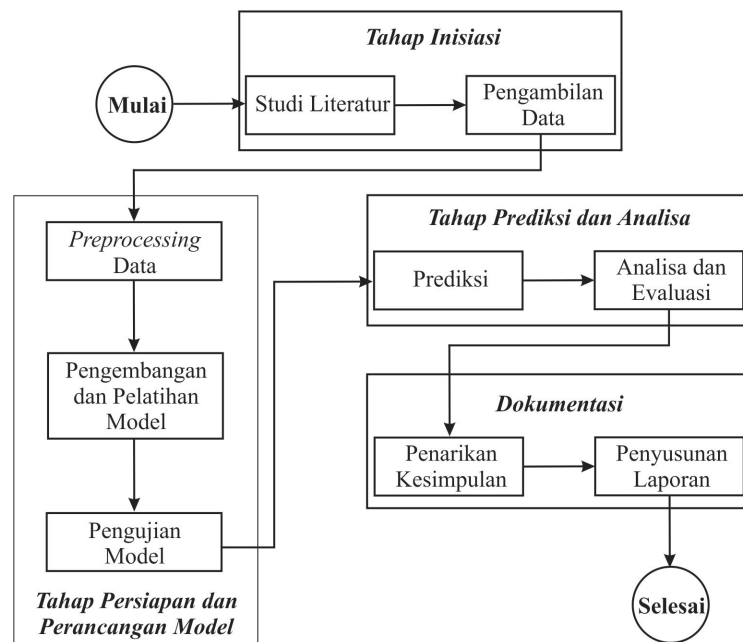
BAB 3

METODE PENELITIAN

Pada bab ini, dijelaskan tentang tahapan-tahapan penelitian yang dilakukan untuk menyelesaikan masalah yang telah dikemukakan pada rumusan masalah. Ditunjukkan pula jadwal penelitian untuk masing-masing tahapan penelitian tersebut.

3.1 Tahapan Penelitian

Metode pengerjaan tugas akhir ini dijelaskan pada Gambar 3.1 berikut:



Gambar 3.1: Metode Pengerjaan Penelitian

Metode pengerjaan tugas akhir ini terdiri dari empat langkah utama, yaitu: tahap inisiasi, tahap persiapan dan perancangan model, tahap prediksi dan analisa serta tahap dokumentasi. Tahap perancangan model dan prediksi dilakukan menggunakan bahasa python 3.6.

3.1.1 Tahap Inisiasi

Inisiasi merupakan tahap pertama dalam penelitian ini. Dalam tahap ini dilakukan pengambilan dan analisis data serta melakukan studi literatur

pendukung. Tahap ini secara umum terbagi dua sub tahapan sebagai berikut:

1. Studi Literatur

Dilakukan studi literatur untuk mendukung pengerjaan penelitian ini dan pemahaman yang lebih mendalam mengenai metode *extreme learning machine* serta hubungan antara cuaca dan kejadian demam berdarah. Literatur yang dipelajari dapat bersumber dari jurnal, buku, internet, maupun bimbingan dengan dosen pembimbing.

2. Pengambilan Data

Data yang akan digunakan dalam penelitian ini berupa data sekunder yang terbagi atas data faktor cuaca dan kasus demam berdarah.

- Data Cuaca diperoleh dari BPS DKI Jakarta
- Data kasus demam berdarah di peroleh dari dinas kesehatan DKI Jakarta

3.1.2 Tahap Persiapan dan Perancangan Model

Setelah menentukan tujuan penelitian dan pengambilan data pada tahap sebelumnya, selanjutnya dilakukan persiapan data dan perancangan model.

1. *Preprocessing* data

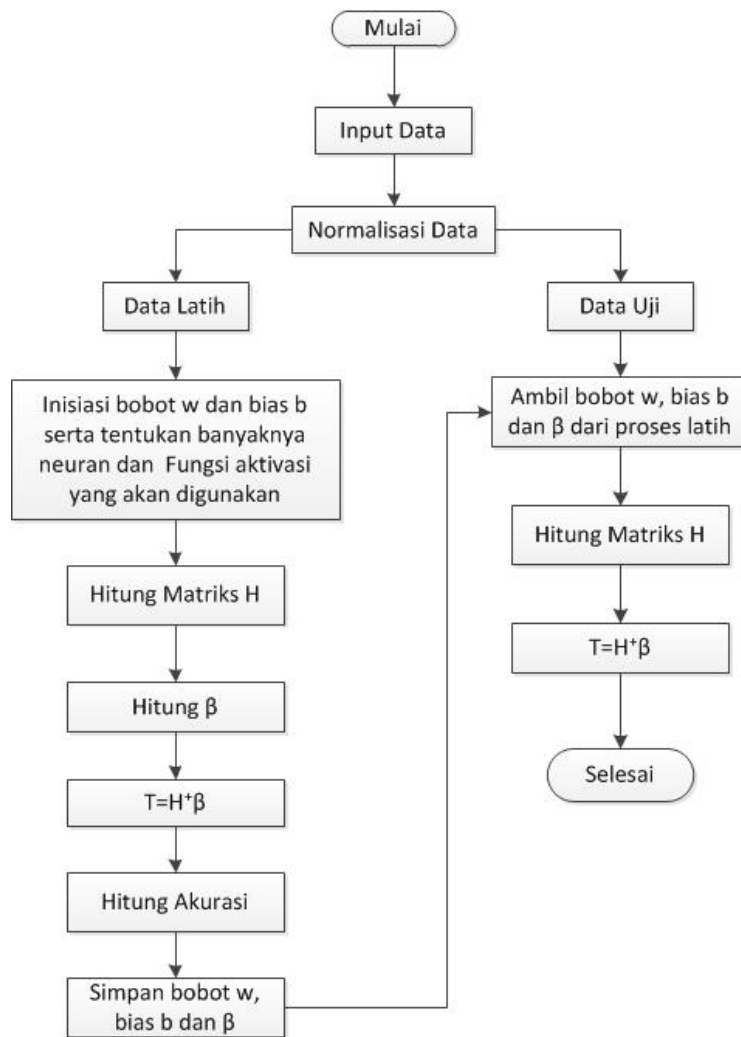
Pada tahap ini data yang telah dikumpulkan akan dinormalisasi sehingga mempunyai nilai dengan rentang tertentu. Selanjutnya data akan dibagi menjadi dua kelompok yaitu data *training* dan data *testing*. Data tersebut akan dibagi dengan komposisi 75% untuk data *training* dan 25% untuk data *testing*.

2. Perancangan dan Pelatihan Model

Pelatihan atau lebih dikenal dengan istilah *training* adalah proses pengenalan pola-pola daya yang telah dinormalisasikan agar sistem dapat menentukan bobot-bobot yang memetakan antara *input* dan target *output* yang diinginkan. Pada proses *training* ini, jumlah *hidden neuron* dan fungsi aktivasi dari ELM akan ditentukan. Output dari proses pelatihan ELM adalah bobot serta bias dari *hidden neuron* dengan tingkat kesalahan rendah.

3. Pengujian Model

Setelah bobot dan bias dari proses *training* diperoleh, maka tahap



Gambar 3.2: Tahapan Persiapan dan Perancangan Model

selanjutnya adalah melakukan pengujian terhadap model jaringan syaraf tiruan yang telah dibangun, tahap ini juga dikenal seabgai proses *testing*. Data yang digunakan adalah data *testing* sebanyak 25% dari data total.

3.1.3 Tahap Prediksi dan Analisa

Setelah dilakukan proses pengolahan data dan perancangan model yang sesuai, selanjutnya dilakukan proses prediksi menggunakan data dan model yang telah dikembangkan pada tahap sebelumnya. Dengan menggunakan bobot untuk tiap unit dari model jaringan syaraf tiruan tersebut diharapkan untuk mendapatkan nilai kesalahan yang paling minimum. Setelah prediksi dilakukan dan didapatkan hasil prediksi, dilakukan analisa dan evaluasi hasil prediksi apakah telah sesuai dengan yang diharapkan.

3.1.4 Penarikan Kesimpulan

Penarikan kesimpulan dilakukan dengan memperhatikan hasil dari analisa prediksi wabah demam berdarah dengue berdasarkan keadaan cuaca. Kesimpulan yang ditarik apakah metode ELM dapat digunakan untuk melakukan prediksi kejadian demam berdarah berdasarkan keadaan cuaca.

3.1.5 Penyusunan Laporan

Seluruh tahapan yang dilakukan hingga menghasilkan data yang diinginkan didokumentasikan dalam sebuah laporan. Laporan ini ditulis berdasarkan panduan yang berlaku di Departemen Matematika, Fakultas Matematika, Komputasi dan Data Sains.

3.2 Tempat Penelitian

Penelitian ini dilakukan di Laboratorium Ilmu Komputer, Jurusan Matematika, Fakultas Matematika, Komputasi, dan Sains Data, Institut Teknologi Sepuluh Nopember Surabaya.

BAB 4

HASIL DAN PEMBAHASAN

4.1 Perancangan Data

Untuk dapat melakukan peramalan dan prediksi dengan *machine learning*, dibutuhkan data dan informasi yang memadai. Data yang digunakan dalam penelitian ini terdiri dari dua jenis yakni data keadaan cuaca dan data kejadian DBD di DKI Jakarta. Data kejadian DBD tahun 2008 sampai dengan tahun 2016 diperoleh dari dinas kesehatan DKI Jakarta sebagaimana ditunjukkan pada Tabel 4.1. Sedangkan untuk keadaan cuaca digunakan data sekunder yang bersumber dari BPS DKI Jakarta.

Selanjutnya, jumlah kasus di DKI Jakarta setiap bulannya ditransformasi menjadi angka insiden menggunakan persamaan 2.1. Sebagai contoh, pada bulan Januari tahun 2008, dari Tabel 4.1 diperoleh informasi bahwa jumlah kasus DBD di DKI Jakarta adalah 3082. Jika jumlah penduduk DKI Jakarta pada waktu tersebut adalah 9146181 orang, maka angka insiden demam berdarah di DKI Jakarta pada bulan Januari 2008 adalah :

$$AI = \frac{3082 \times 100000}{9146181}$$
$$AI = 33.69712$$

Angka Insiden yang diperoleh sebesar 33.69717 menandakan bahwa pada bulan Januari tahun 2008 tingkat risiko demam berdarah di DKI Jakarta termasuk golongan risiko tinggi. Dengan cara yang sama angka insiden kejadian demam berdarah di DKI Jakarta bulan Februari tahun 2008 hingga bulan Desember tahun 2016 dapat dihitung, hasilnya ditampilkan pada Gambar 4.1


Pada penelitian ini, keadaan cuaca diwakili oleh temperatur, kelembaban relatif dan curah hujan. Temperatur terdiri atas 3 variabel yaitu temperatur maksimum, temperatur minimum dan temperatur rata-rata. Begitu juga dengan kelembaban relatif terdiri atas 3 variabel yaitu kelembaban maksimum, kelembaban minimum, dan kelembaban relatif. Selanjutnya setiap variabel keadaan cuaca dihitung korelasinya dengan tingkat risiko wabah DBD dengan cara membandingkan koefisien relasi hasil perhitungan (r) dengan

Tabel 4.1: Banyaknya Kasus DBD di DKI Jakarta

Tahun		Banyaknya Kasus DBD						
		Pusat	Utara	Barat	Selatan	Timur	Kep. Seribu	DKI
2008	1	441	487	436	944	774	0	3082
	2	303	381	380	763	801	0	2628
	3	363	394	475	691	924	0	2847
	4	516	486	674	819	1269	0	3764
	5	556	620	747	940	1910	0	4773
	6	419	502	488	760	1382	0	3551
	7	179	269	311	438	608	0	1805
	8	124	191	208	270	291	0	1084
	9	91	137	182	210	195	0	815
	10	117	149	209	274	205	0	954
	11	121	171	170	329	240	0	1031
	12	228	265	244	625	411	1	1774
.
.
.
2016	1	220	392	324	569	516	0	2021
	2	357	776	767	1013	1149	4	4066
	3	615	992	1045	1361	1845	1	5859
	4	694	1343	1605	1353	2277	1	7273
	5	342	817	834	910	1425	0	4328
	6	210	505	616	707	1053	2	3093
	7	179	317	505	579	690	4	2274
	8	205	321	690	560	685	2	2463
	9	172	293	567	445	573	2	2052
	10	159	260	552	501	628	1	2101
	11	173	286	536	461	815	1	2272
	12	137	254	445	406	619	2	1863

r_{tabel} . Apabila r hasil perhitungan lebih dari r_{tabel} maka dapat ditarik kesimpulan bahwa variabel tersebut memiliki korelasi yang signifikan dengan tingkat risiko wabah DBD. Sebaliknya jika r hasil perhitungan kurang dari r_{tabel} , hal ini menunjukkan bahwa variabel tersebut tidak memiliki korelasi yang signifikan dengan insiden demam berdarah. Dengan banyak data(n)= 108 dan $\alpha = 0.05$ maka r_{tabel} yang digunakan dalam penelitian ini adalah 0.1591. Untuk menghitung koefisien relasi (r) digunakan rumus berikut:

$$r = \frac{n\Sigma XY - (\Sigma X)(\Sigma Y)}{\sqrt{(n\Sigma X^2 - (\Sigma X)^2)(n\Sigma Y^2 - (\Sigma Y)^2)}}$$



Gambar 4.1: Angka Insiden Demam Berdarah DKI Jakarta Tahun 2008 - 2016

Jika kita misalkan X adalah temperatur maksimum dan Y adalah insiden demam berdarah, maka akan diperoleh koefisien relasi antara temperatur maksimum dan insiden demam berdarah sebagai berikut:

$$r = \frac{n\Sigma XY - (\Sigma X)(\Sigma Y)}{\sqrt{(n\Sigma X^2 - (\Sigma X)^2)(n\Sigma Y^2 - (\Sigma Y)^2)}}$$

$$r = \frac{67441.00369 - (3625.65 \times 2025.87)}{\sqrt{(13167893.36 - 13145337.92)(5972176.42 - 4104132.487)}}$$

$$r = -0.299376706$$

Dari hasil perhitungan diperoleh $r = 0.299376706$ dimana tanda negatif menunjukkan arah korelasi. Karena $r > r_{tabel}$ maka dapat ditarik kesimpulan bahwa ada korelasi yang cukup signifikan antara temperatur maksimum dan insiden demam berdarah. Dengan cara yang sama koefisien korelasi tiap variabel keadaan cuaca dan insiden demam berdarah dihitung, hasilnya ditampilkan pada Tabel 4.2.

Berdasarkan hasil perhitungan sebagaimana yang ditampilkan pada Tabel 4.2, hanya 4 variabel cuaca yang berkorelasi secara signifikan terhadap insiden demam berdarah, yaitu temperatur maksimum, temperatur minimum, kelembaban minimum dan kelembaban rata-rata. Selanjutnya keempat variabel tersebut akan digunakan sebagai variabel input dalam jaringan extreme learning machine.

Tabel 4.2: Koefisien relasi variabel cuaca dan insiden demam berdarah

Variabel Cuaca	Koefisien relasi (r)
Temperatur Maksimum	-0.299
Temperatur Minimum	0.282
Temperatur rata-rata	-.127
Kelembapan Maksimum	.108
kelembaban Minimum	0.359
kelembaban rata-rata	0.362
Curah Hujan	.155

4.1.1 *Preprocessing Data*

Pada tahap ini data yang telah dikumpulkan akan dinormalisasi atau ditransformasi ke dalam rentang (0,1) menggunakan persamaan 2.9. Misalnya untuk variabel temperatur maksimum dengan nilai tertinggi adalah 37 derajat celsius dan nilai terendah adalah 29.4 derajat celsius, maka nilai 31.8 derajat celsius akan ditransormasi ke dalam rentang [0,1] dengna cara berikut:

$$x'_{ki} = \frac{(x_{ki} - x_{kmin})(Hi - Lo)}{(x_{kmax} - x_{kmin})} + Lo$$

$$x'_{ki} = \frac{(31.8 - 29.4)(1 - 0)}{(37 - 29.4)} + 0$$

$$x'_{ki} = 0.32$$

Hal ini dilakukan untuk setiap nilai pada setiap variabel cuaca, pengerjaan ini tentu saja tidak dilakukan secara manual namun menggunakan bantuan program. Pada Gambar 4.2 kami tampilkan potongan *psedocode* program yang kami gunakan untuk melakukan normalisasi data.

Sebagaimana yang telah dijelaskan sebelumnya, variabel cuaca ini akan digunakan sebagai prediktor sedangkan sebagai target akan digunakan angka insiden DBD yang telah diklasifikasikan ke dalam 3 kategori. ketiga kategori tersebut yaitu risiko tinggi, risiko sedang dan risiko rendah sebagaimana yang telah dielaskan pada bagian 2.2. Untuk dapat diproses dalam jaringan extreme learning machine setiap kategori tersebut kemudian dikodekan kedalam bentuk numerik. Pada penelitian ini, kategori risiko tinggi diberi nilai 3, risiko sedang diberi nilai 2 sedangkan kategori risiko rendah diberi nilai 1. Selanjutnya data akan dibagi menjadi dua kelompok yaitu data *training* dan data *testing*, dengan komposisi 75% untuk data *training* dan 25% untuk data *testing*.

```

input = dataMentah (data set yang akan ditransformasi)
        skalaMax (1)
        skalaMin(0)
output = data set dengan rentang nilai (0,1)

def normFunc(dataMentah,skalaMax,skalaMin):
    (m,n)=dataMentah.shape
    global x_max
    global x_min
    x_max = np.array(np.zeros([n, 1]))
    x_min = np.array(np.zeros([n, 1]))
    for i in range(0, n):
        x_max[i] = max(dataMentah[:, i])
        x_min[i] = min(dataMentah[:, i])
    x_norm = np.array(np.zeros([m, n]))
    for j in range(0, m):
        for j2 in range(0, n):
            x_norm[j, j2] = (((skalaMax-skalaMin) * (dataMentah[j, j2] -
x_min[j2])) / (x_max[j2] - x_min[j2])) + skalaMin
    return x_norm

```

Gambar 4.2: *Pseudocode* untuk normalisasi data

4.2 Perancangan dan Pelatihan Model Jaringan Syaraf Tiruan

Pada tahap ini akan dikembangkan model jaringan syaraf tiruan *Extreme Learning Machine* untuk mendeskripsikan hubungan keadaan cuaca dengan tingkat risiko wabah DBD. Selain itu, pada tahap ini juga akan dilakukan peramalan keadaan cuaca yang nantinya akan digunakan untuk prediksi tingkat risiko wabah DBD.

4.2.1 Klasifikasi Tingkat Risiko Wabah Demam Berdarah Berdasarkan Keadaan Cuaca

Sebelum melakukan prediksi tingkat resiko wabah DBD berdasarkan keadaan cuaca, terlebih dahulu kita mencari tahu pola hubungan antara cuaca dan wabah DBD. Pada bagian ini akan dibahas mengenai implementasi metode ELM untuk melakukan klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca. Proses ini didahului dengan penyiapan data, dilanjutkan dengan proses training kemudian testing.

Perencanaan arsitektur jaringan *Extreme learning machine* pada penelitian ini terdiri dari *input layer*, *hidden layer* dan *output layer* serta fungsi aktivasi sebagai parameter yang akan digunakan dalam proses perencanaan model. Input layer terdiri dari 4 neuron output yaitu suhu maksimum, suhu minimum, kelembaban rata-rata dan kelembaban minimum. Sedangkan output layer terdiri dari 1 neuron yaitu tingkat resiko wabah demam berdarah. Adapun *hidden layer* terdiri dari satu layer yang berisi beberapa neuron dengan fungsi aktivasi tertentu. Banyaknya neuron yang optimal pada *hidden layer* ini ditentukan dengan proses *trial* dan *error* dalam kisaran 5 - 200

neuron. Rincian rancangan model Jaringan *extreme Learning Machine* untuk pengenalan pola hubungan keadaan cuaca dan tingkat resiko wabah demam berdarah dapat dilihat pada tabel berikut:

Tabel 4.3: Rancangan Model jaringan

Parameter	Jumlah	Deskripsi
Input layer	4 neuron	Temperatur maksimum, Temperatur minimum, kelembaban minimum, kelembaban rata-tara
Output layer	1 neuron	Tingkat resiko wabah demam berdarah
Hidden layer	trial dan error	5 - 200 error
Fungsi aktivasi	2	Sigmoid biner dan sigmoid bipolar

4.2.1.1 Data Input

Data yang digunakan pada penelitian ini adalah banyaknya kasus DBD dan keadaan cuaca di DKI Jakarta dalam rentang Januari 2008 hingga Desember 2016. Setelah melalui proses *preprocessing* sebagaimana yang telah dijelaskan pada bagian sebelumnya, data ini kemudian dibagi menjadi data 2 kelompok. Dimana, 75% dari total data digunakan pada proses training sedangkan 25% lainnya digunakan pada proses testing.

4.2.1.2 Proses *Training*

Setelah data siap, langkah selanjutnya adalah melakukan perancangan model Jaringan *extreme Learning Machine* untuk klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca. Secara garis besar perencanaan model jaringan ini terdiri dari dua tahap yaitu proses *training* dan *testing*. Pada proses training matriks bobot input w dan vektor bias b akan dibangkitkan secara random, kemudian akan diperoleh matriks H dan bobot β . Bobot-bobot ini yang nantinya digunakan pada proses testing.

- Inisiasi

Pada metode *extreme learning machine* bobot input dan bias ditentukan secara random. Bobot input berupa matriks $m \times n$ dimana m merupakan banyaknya variabel input dan n adalah banyaknya *hidden neuron*. Sedangkan bias merupakan vektor dengan banyak elemennya sama dengan banyaknya *hidden neuron*. Bobot w dan bias b tersebut dibangkitkan menggunakan fungsi random pada program python dengan syntax sebagai berikut:

```
w=np.random.randn(m,n)
b=np.random.randn(1,n)
```

Maka dengan 4 *input neuron* dan 5 *hidden neuron* diperoleh matriks bobot input w dan vektor bias b berikut:

$$w = \begin{bmatrix} 1.241649 & 0.658632 & -1.595189 & 0.175619 & 1.102255 \\ -1.135579 & -1.172310 & -0.213822 & 0.294932 & -0.964744 \\ 1.511114 & -0.056866 & 1.10165 & 0.939532 & -0.037940 \\ -0.274447 & 0.438450 & 1.281150 & 0.880659 & -0.090184 \end{bmatrix}$$

$$b = \begin{bmatrix} 1.754744 & -0.058474 & 0.052123 & -0.947374 & -0.309368 \end{bmatrix}$$

- Hitung Matriks H

Matriks H atau matriks *hidden layer output* dapat dibentuk menggunakan persamaan 2.14 dimana ukurannya adalah $N \times \tilde{N}$, dengan N adalah banyaknya data dan \tilde{N} adalah banyaknya *hidden neuron*. Selanjutnya matriks H dikenakan fungsi aktivasi sebelum diproses lebih lanjut. Misal digunakan $g(x)$ sebagai fungsi aktivasi sigmoid bipolar sebagaimana persamaan 2.8, maka akan diperoleh matriks H sebagai berikut:

$$g(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \cdots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}$$

$$H = \begin{bmatrix} 0.80366655 & -0.29615188 & 0.40712425 & 0.62189037 & -0.38642733 \\ 0.89982469 & 0.18811651 & -0.03844061 & 0.26309904 & 0.12342607 \\ 0.88596677 & -0.08752783 & 0.28937637 & 0.62027534 & -0.16598946 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.92042105 & 0.04006702 & 0.16545763 & 0.58881195 & -0.00967082 \\ 0.93008817 & 0.2668816 & 0.65614354 & 0.70840868 & 0.0011762 \\ 0.91387571 & 0.01657436 & -0.12105549 & 0.32904144 & 0.04236932 \end{bmatrix}$$

- Hitung β

Bobot β diperoleh dari perkalian invers matriks H yang telah dikenakan fungsi aktivasi dengan target. Dalam hal ini invers matriks H tidak selalu ada, oleh karena itu digunakan Moore-Penrose Generalized inverse.

$$\beta = H^\dagger Y$$

dimana,

$$H^\dagger = (H^T H)^{-1} H^T$$

sehingga,

$$\begin{aligned} \beta &= (H^T H)^{-1} H^T Y \\ \beta &= \begin{bmatrix} 3.960566 & -3.820241 & 2.25366 & -1.65119 & 3.271181 \end{bmatrix} \end{aligned}$$

Setelah mendapatkan bobot output β selanjutnya prediksi tingkat resiko wabah demam berdarah dapat diperoleh menggunakan persamaan 2.13

$$\begin{aligned} Y_{pred} &= H\beta \\ Y_{pred} &= \begin{bmatrix} 0.80366655 & -0.29615188 & 0.40712425 & 0.62189037 & -0.38642733 \\ 0.89982469 & 0.18811651 & -0.03844061 & 0.26309904 & 0.12342607 \\ 0.88596677 & -0.08752783 & 0.28937637 & 0.62027534 & -0.16598946 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.92042105 & 0.04006702 & 0.16545763 & 0.58881195 & -0.00967082 \\ 0.93008817 & 0.2668816 & 0.65614354 & 0.70840868 & 0.0011762 \\ 0.91387571 & 0.01657436 & -0.12105549 & 0.32904144 & 0.04236932 \end{bmatrix} \begin{bmatrix} 3.960566 \\ -3.820241 \\ 2.25366 \\ -1.65119 \\ 3.271181 \end{bmatrix} \\ Y_{pred} &= \begin{bmatrix} 2.9409 \\ 2.7279 \\ 2.9283 \\ \vdots \\ 2.8613 \\ 2.9770 \\ 2.8786 \end{bmatrix} \end{aligned}$$

Y_{pred} yang diperoleh kemudian dibandingkan dengan data aktual (Y) untuk menghitung akurasi model jaringan ELM yang telah dibangun.

- Hitung Error

Akurasi atau performa dari model yang telah dilatih dilihat dari nilai MAPE setiap model tersebut. Semakin kecil nilai MAPE yang diperoleh

mengindikasikan performa yang semakin baik. Untuk menghitung nilai MAPE dapat digunakan persamaan 2.18.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{P_i} \right| \times 100\%$$

$$MAPE = \frac{1}{750} \sum_{i=1}^{750} \left| \frac{Y_{pred_i} - Y_i}{Y_i} \right| \times 100\%$$

$$MAPE = \frac{1}{750} \times (45.0647814787187) \times 100\%$$

$$MAPE = 6.008637530495826\%$$

Berikut kami tampilkan potongan *pseudocode* yang merupakan terjemahan persamaan 2.18 ke dalam bahasa pemrograman.

```

Input = nilai prediksi dan nilai sebenarnya
Output = MAPE dan MAE

def MAPE(prediksi, aktual):
    return (np.mean(np.abs((aktual - prediksi)/aktual)) * 100)

def MAE(prediksi, aktual):
    return (np.mean(np.abs(aktual-prediksi)))

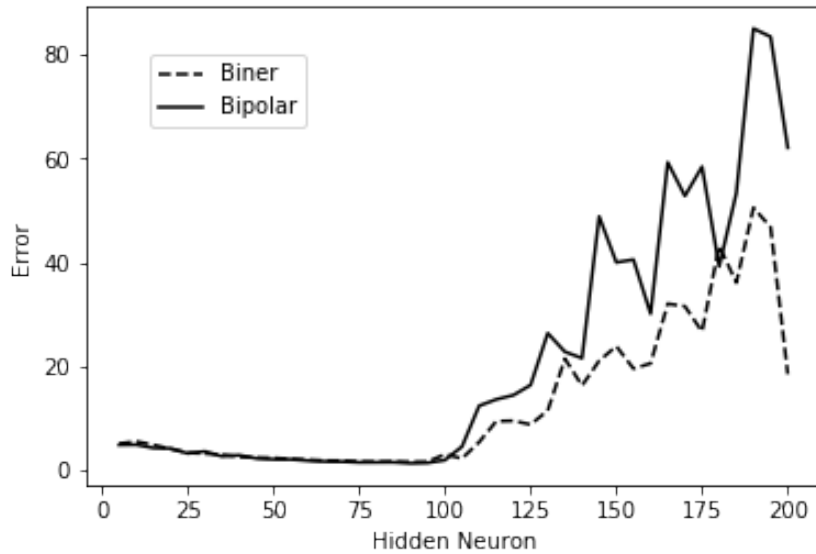
```

Gambar 4.3: *Pseudocode* untuk mengukur performa model jaringan

4.2.1.3 Testing

Pada proses testing langkah-langkah yang digunakan sama dengan proses *training*. Akan tetapi, pada proses *testing* seluruh bobot diambil dari hasil training. Sehingga dalam proses testing tidak ada lagi penghitungan bobot β . Data yang digunakan juga berbeda dengan data yang digunakan pada proses training sebagaimana yang telah dijelaskan pada tahap *preprocessing* data. Setelah itu, tingkat akurasi dihitung dengan cara yang sama seperti pada proses training.

Gambar 4.4 menyajikan performa model jaringan ELM yang telah dibangun untuk melakukan klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca. Garis hitam menunjukkan performa jaringan dengan fungsi aktivasi sigmoid bipolar, sedangkan garis putus-putus menunjukkan performa dengan fungsi aktivasi sigmoid biner. Gambar tersebut juga memberi informasi bahwa semakin banyak *hidden neuron* tidak menjamin semakin baik performa model jaringan yang telah dibangun. Hal ini juga




Gambar 4.4: Performa Jaringan ELM berdasarkan Fungsi Aktivasi dan Banyaknya *Hidden Neuron*

sejalan dengan penelitian yang telah dilakukan oleh Ariestyani dkk (2018), dimana mereka melakukan penelitian dengan melakukan variasi pada jumlah *hidden neuron*nya yaitu 10 hingga 200 dan memperoleh akurasi terbaik dengan 10 *hidden neuron*. Untuk memperoleh performa terbaik penentuan jumlah *hidden neuron* dan fungsi aktivasi merupakan hal yang penting. Selain masalah akurasi, banyaknya *hidden neuron* juga sangat mempengaruhi waktu komputasi. Berdasarkan percobaan yang telah dilakukan pada penelitian ini performa terbaik jaringan ELM untuk klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca adalah jaringan ELM dengan fungsi aktivasi bipolar dan 90 *hidden neuron*.

Pada Gambar 4.5 ditampilkan model terbaik jaringan ELM yang diperoleh untuk klasifikasi tingkat risiko wabah demam berdarah. Dimana, X_1, \dots, X_4 merupakan variabel cuaca yakni temperatur maksimum, temperatur minimum, kelembaban minimum dan kelembaban rata-rata. Sedangkan Z_1, \dots, Z_{90} merupakan keluaran dari setiap *hidden neuron* yang telah dikenakan fungsi aktivasi sigmoid bipolar. Secara matematis model jaringan tersebut dapat dituliskan secara matematis sebagai berikut:

$$\sum_{j=1}^{90} \beta_j Z_j = Y_i, \quad i = 1, \dots, N,$$



Gambar 4.5: Model Terbaik Jaringan ELM Untuk Klasifikasi Tingkat Risiko Wabah Demam Berdarah Berdasarkan Keadaan Cuaca

dimana,

$$Z = g(w_j \cdot x_i + b_j)$$

Model jaringan ELM yang diperoleh ini selanjutnya divalidasi menggunakan data aktual tahun 2015 dan 2016. Hasil validasi ini ditampilkan pada Tabel 4.4. Dari tabel tersebut dapat diperoleh informasi bahwa model jaringan yang telah dibangun dapat dengan tepat mengklasifikasikan tiap kelas tingkat risiko dengan perorma yang sangat baik. Performa yang baik ini dapat dilihat dari rendahnya nilai MAPE yang diperoleh yaitu 1.5403%.

4.2.2 Peramalan Keadaan Cuaca

Keadaan cuaca menjadi variabel prediktor dalam proses prediksi tingkat resiko wabah demam berdarah yang dilakukan dalam penelitian ini. Berdasarkan analisis korelasi yang dilakukan pada sub bab 4.1 ada 4 variabel cuaca yang secara signifikan berpengaruh pada tingkat resiko wabah demam berdarah. Peramalan keadaan setiap variabel cuaca tersebut perlu dilakukan dalam rangka membangun sebuah sistem prediksi tingkat resiko berdasarkan keadaan cuaca. Proses peramalan keadaan cuaca ini kembali memanfaatkan Metode *extreme learning machine*, dengan tahapan proses peramalan didahului dengan penyiapan data, dilanjutkan dengan proses training kemudian testing.

Arsitektur jaringan *Extreme learning machine* untuk peramalan

Tabel 4.4: Hasil klasifikasi tingkat resiko wabah demam berdarah berdasarkan keadaan cuaca

Tingkat Resiko			Selisih	APE
Prediksi	Kelas Prediksi	Kelas Aktual		
2.999948	3	3	5.24176E-05	0.0017%
3.001431	3	3	0.001430851	0.0477%
3.000667	3	3	0.000667296	0.0222%
2.995882	3	3	0.004118026	0.1373%
2.984632	3	3	0.015368447	0.5123%
3.04576	3	3	0.04576048	1.5253%
3.002353	3	3	0.002353093	0.0784%
1.998332	2	2	0.001667585	0.0834%
2.006014	2	2	0.006013593	0.3007%
2.002254	2	2	0.002254239	0.1127%
2.358	2	2	0.357999561	17.9000%
3.024641	3	3	0.024640627	0.8214%
2.991912	3	3	0.008087708	0.2696%
2.997636	3	3	0.002363907	0.0788%
3.01318	3	3	0.013179959	0.4393%
2.991791	3	3	0.008208745	0.2736%
3.004965	3	3	0.004964924	0.1655%
2.989111	3	3	0.010889394	0.3630%
3.265132	3	3	0.265131551	8.8377%
2.985173	3	3	0.014826841	0.4942%
2.93058	3	3	0.069420071	2.3140%
3.051531	3	3	0.051531311	1.7177%
2.989538	3	3	0.01046171	0.3487%
2.996335	3	3	0.003664572	0.1222%
MAPE				1.5403%

keadaan cuaca terdiri dari *input layer*, *hidden layer* dan *output layer* serta fungsi aktivasi sebagai parameter yang akan digunakan dalam proses perencanaan model. Input layer adalah keadaan variabel cuaca dimasa lalu ($t, t - 1, t - 2, \dots, t - n$). Sedangkan output layer adalah keadaan cuaca dimasa yang akan datang ($t + 1$). Adapun hidden layer terdiri dari satu layer yang berisi beberapa neuron dengan fungsi aktivasi tertentu. Banyaknya neuron yang optimal pada *hidden layer* ini ditentukan dengan proses *trial* dan *error* dalam kisaran 5 - 200 neuron. Rincian rancangan model Jaringan *extreme Learning Machine* untuk peramalan keadaan cuaca dapat dilihat pada Tabel 4.5

4.2.2.1 Dataset

Data yang digunakan adalah data keadaan cuaca (temperatur maksimum, temperatur minimum, kelembapan minimum dan kelembapan rata-

Tabel 4.5: Rancangan Model Jaringan untuk Peramalan Keadaan Cuaca

Parameter	Jumlah	Deskripsi
Input layer	<i>trial and error</i>	4,6,12 neuron
Output layer	1 neuron	Hasil Peramalan Keadaan Cuaca
Hidden layer	<i>trial and error</i>	5 - 200 neuron
Fungsi aktivasi	2	Sigmoid biner dan sigmoid bipolar

rata) dalam rentang Januari 2005 - Desember 2016 seperti ditunjukkan pada Tabel 4.6

Tabel 4.6: Keadaan cuaca tahun Januari 2005 - Desember 2016

Tahun	Temperatur		kelembaban	
	Maksimum	Minimum	Minimum	Rata-rata
2005	33.20	24.10	54.00	79.00
	33.40	23.80	55.00	79.00
	33.60	23.40	54.00	77.50
	35.00	24.50	49.00	73.00
	35.00	24.60	49.00	73.00
	34.60	24.20	49.00	74.00
	34.00	24.20	45.00	72.00
⋮	⋮	⋮	⋮	⋮
2016	34.00	24.30	72.00	80.00
	32.60	24.00	71.00	82.80
	33.60	24.40	74.00	81.00
	34.70	24.80	72.00	77.00
	35.20	25.00	72.00	78.40
	35.00	23.40	69.00	76.10
	35.00	24.00	69.00	77.20
	34.40	24.00	59.00	76.10
	35.20	24.20	67.00	76.40
	33.80	24.20	66.00	77.20
	34.20	24.70	68.00	76.80
	34.40	24.00	67.00	75.30

Arsitektur ELM yang dibangun pada proses peramalan keadaan cuaca ini sedikit berbeda dengan proses klasifikasi yang telah dilakukan sebelumnya. Pada proses peramalan ini, banyaknya neuron input bervariasi sebagaimana yang ditunjukkan pada Tabel 4.5 . Karena perbedaan arsitektur ini maka dataset pada proses peramalan keadaan cuaca juga disiapkan dengan cara

yang berbeda. Langkah awal yang perlu dilakukan adalah menentukan banyaknya neuron input yang akan digunakan. Selanjutnya membentuk matriks input yang akan digunakan dalam proses training. *Pseudocode* untuk membentuk matriks input peramalan temperatur maksimum ditunjukkan pada Gambar 4.6. Pada baris pertama kita diminta untuk menentukan banyaknya neuron input yang dikehendaki (n). Selanjutnya akan dibentuk matriks yang ukurannya sesuai dengan banyaknya data serta banyaknya neuron input yang sudah ditentukan tadi. Matriks ini kemudian diisi dengan data-data temperatur maksimum yang sudah diurutkan, hasilnya dapat dilihat pada Tabel 4.7

```

n= banyaknya neuron input
Tmax=np.array(np.zeros((len(data)-n+1,n)))
Tmax_temp=data[:,0]
for i in range (len(Tmax)):
    for j in range (0,n):
        Tmax[i,j]=Tmax_temp[i+j]
(u,v)=np.shape (Tmax)
varInput=Tmax[:,0:v-1]
target=Tmax[:,v-1]

```

Gambar 4.6: Pembentukan Dataset Peramalan Temperatur Maksimum

Selanjutnya dengan cara yang sama matriks-matriks input dari setiap variabel cuaca dapat dibentuk.

Tabel 4.7: Dataset Peramalan Temperatur Maksimum dengan 6 Neuron Input

X1	X2	X3	X4	X5	X6	Y
33.2	33.4	33.6	35	35	34.6	34
33.4	33.6	35	35	34.6	34	34.8
33.6	35	35	34.6	34	34.8	35
35	35	34.6	34	34.8	35	35.3
35	34.6	34	34.8	35	35.3	34.4
⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮
32.6	33.6	34.7	35.2	35	35	34.4
33.6	34.7	35.2	35	35	34.4	35.2
34.7	35.2	35	35	34.4	35.2	33.8
35.2	35	35	34.4	35.2	33.8	34.2
35	35	34.4	35.2	33.8	34.2	34.4

4.2.2.2 Training

Setelah dataset disiapkan, langkah selanjutnya adalah melakukan perancangan model Jaringan *extreme Learning Machine* untuk peramalan keadaan cuaca. Sama seperti sebelumnya, secara garis besar perencanaan model jaringan ini terdiri dari dua tahap yaitu proses *training* dan *testing*. Pada proses *training* data yang digunakan sebanyak 75% dari dataset yang telah disiapkan.

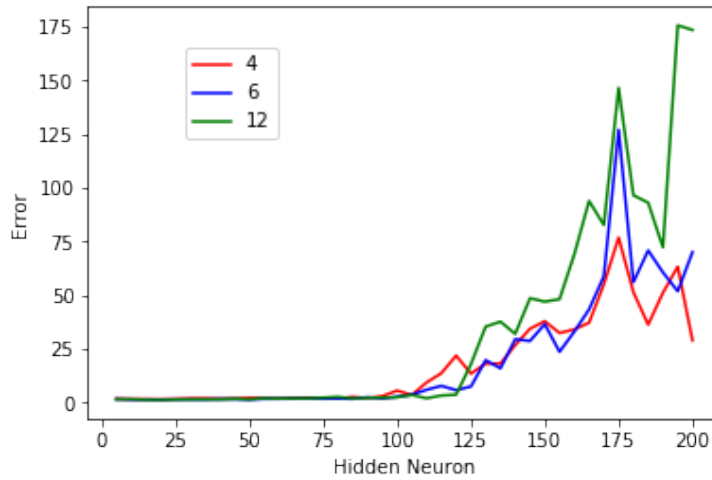
4.2.2.3 Testing

Proses testing pada tahap ini bertujuan untuk mengukur performa model jaringan yang telah dibangun pada proses training. Sama seperti pada tahap klasifikasi, pada proses testing ini bobot β yang digunakan merupakan hasil dari proses pelatihan. Adapun data yang digunakan yaitu 25% dari dataset yang telah disiapkan.

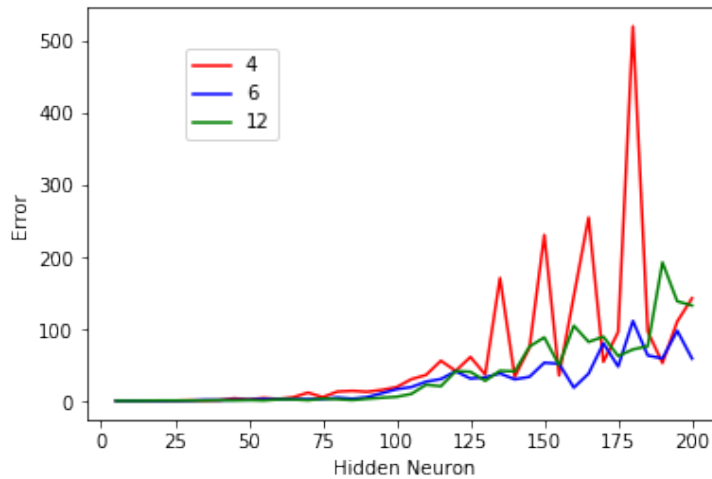
Gambar 4.7(a) dan Gambar 4.7(b) disajikan grafik performa ELM untuk peramalan temperatur maksimum dengan fungsi aktivasi sigmoid biner dan sigmoid Bipolar. Garis berwarna merah menunjukkan peroforma model jaringan dengan 4 neuron input, sedangkan garis berwarna biru dan hijau peroforma model jaringan dengan 6 neuron dan 12 neuron. Jika setiap Berdasarkan percobaan yang dilakukan dalam penelitian ini diperoleh model jaringan ELM terbaik untuk peramalan temperatur maksimum yaitu jaringan ELM yang menggunakan fungsi aktivasi sigmoid bipolar dengan 20 *hidden neuron* dan 12 neuron input. Dilakukan percobaan yang sama pada setiap variabel cuaca. Percobaan tersebut mengacu pada Tabel 4.5. Hasil dari percobaan tersebut secara ringkas ditampilkan pada Tabel 4.8

Tabel 4.8: Performa jaringan ELM untuk peramalan keadaan cuaca

Fungsi Aktivasi	Neuron Input	T maks		T Min		H min		H avg	
		MAPE	HN	MAPE	HN	MAPE	HN	MAPE	HN
Biner	4	1.704	5	2.284	5	6.434	5	2.360	10
	6	1.512	20	2.306	5	6.607	5	2.632	10
	12	1.428	10	2.018	15	6.423	10	3.003	10
Bipolar	4	1.478	20	2.014	40	5.521	10	2.756	5
	6	1.299	50	1.958	5	4.905	20	2.392	15
	12	1.172	20	1.679	25	6.206	20	2.756	5



(a) Fungsi Aktivasi Sigmoid Biner




(b) Fungsi Aktivasi Sigmoid Bipolar

Gambar 4.7: Performa model jaringan ELM untuk peramalan keadaan temperatur maksimum

Dari Tabel 4.8 diperoleh informasi terkait model jaringan ELM terbaik untuk peramalan setiap variabel cuaca. Dari kolom T_{min} diperoleh informasi bahwa model jaringan terbaik untuk peramalan temperatur minimum adalah ELM yang menggunakan fungsi aktivasi sigmoid bipolar dengan 25 *hidden neuron* dan 12 neuron input. Untuk peramalan kelembapan minimum dapat dilihat pada kolom H_{min}, performa terbaik dengan ditunjukkan oleh model jaringan ELM yang menggunakan fungsi sigmoid bipolar dengan 20 *hidden neuron* dan 6 neuron input. Sedangkan untuk peramalan kelembapan rata-rata model terbaik yang diperoleh adalah ELM yang menggunakan fungsi aktivasi

sigmoid biner dengan 10 *hidden neuron* dan 4 neuron input, informasi ini dapat dilihat pada kolom H avg.



Gambar 4.8: Model Terbaik Jaringan ELM Untuk Peramalan Cuaca

Gambar 4.8 Menampilkan model jaringan terbaik untuk peramalan setiap variabel cuaca. Dimana, variabel X merupakan *neuron input*, sedangkan Z merupakan keluaran dari setiap *hidden neuron* yang telah dikenakan fungsi aktivasi dan Y adalah hasil peramalan.

4.2.3 Prediksi Tingkat risiko wabah DBD berdasarkan Cuaca

Setelah diperoleh model jaringan ELM terbaik dengan parameter-parameter yang optimal selanjutnya dilakukan prediksi tingkat resiko wabah demam berdarah dimasa yang akan datang ($t + 1, t + 2, \dots, t + n$). Hal pertama yang perlu dilakukan adalah melakukan peramalan setiap variabel cuaca yang akan menjadi prediktor dengan model jaringan terbaik yang telah dibangun. Hasil peramalan keadaan setiap variabel cuaca selama 12 bulan kedepan menggunakan model terbaik yang telah dibangun ditampilkan pada Tabel 4.9. Hasil peramalan ini selanjutnya digunakan sebagai input pada model

Tabel 4.9: Hasil Peramalan Keadaan Cuaca

Bulan	Temperatur		Kelembaban	
	Maksimum	Minimum	Minimum	Rata-rata
Januari 2017	34.56468165	24.24998965	69.61603879	78.55993683
Februari 2017	34.57256996	24.03646498	68.37704444	74.94412352
Maret 2017	34.02927391	24.46283903	65.84436965	76.72634141
April 2017	33.97939575	24.26289773	60.56852405	75.64965546
Mei 2017	33.92883131	24.74476094	64.59134905	74.99613286
Juni 2017	33.78514448	24.35648025	62.31736986	75.10520551
Juli 2017	34.32156867	24.69365251	66.88409201	74.887061
Agustus 2017	34.30459181	24.42030427	69.55597523	75.71955442
September 2017	34.17391643	24.67507559	66.75637303	75.57490502
Oktober 2017	34.43156406	24.56151054	68.12710484	76.34913934
November 2017	33.97819856	24.93173167	65.09826945	76.85566781
Desember 2017	34.19397749	24.69318261	60.48738043	74.27330931

jaringan ELM untuk klasifikasi tingkat resiko wabah demam berdarah yang telah dibangun. Hasil prediksi tingkat resiko wabah demam berdarah untuk 12 bulan kedepan dapat dilihat pada Tabel 4.10.

Tabel 4.10: Hasil Prediksi Tingkat Resiko Wabah Demam Berdarah Tahun 2017

Bulan	Tingkat Resiko			Selisih	APE
	Prediksi	Kls. Prediksi	Kls. Aktual		
Januari	2.934618	3	3	0.065381912	2.1794%
Februari	3.073686	3	3	0.073685763	2.4562%
Maret	3.061399	3	3	0.061399218	2.0466%
April	3.088185	3	3	0.088185252	2.9395%
Mei	3.125402	3	3	0.12540187	4.1801%
Juni	2.767143	3	3	0.232856503	7.7619%
Juli	2.83755	3	2	0.837550333	41.8775%
Agustus	2.753829	3	2	0.753829001	37.6915%
September	2.829496	3	2	0.829496299	41.4748%
Oktober	2.701098	3	3	0.298902258	9.9634%
November	3.055114	3	3	0.055113772	1.8371%
Desember	2.817519	3	3	0.182481355	6.0827%
MAPE					13.3742%

Dari Tabel 4.10 diperoleh informasi bahwa model jaringan ELM yang telah dibangun dapat memprediksi tingkat resiko wabah demam berdarah dengan error 13.372%. Nilai ini jauh lebih besar dari nilai MAPE yang diperoleh pada proses klasifikasi. Selain itu, performa ini juga lebih rendah dibanding performa rata-rata penerapan ELM sebagaimana yang ada dalam (Huang dkk, 2006) dan (Najar, A.M. dkk, 2018). Hal ini dikarenakan pada penelitian-penelitian lainnya variabel input merupakan nilai aktual, sedangkan pada model ini variabel input yang digunakan yaitu keadaan cuaca adalah hasil peramalan. Proses Peramalan cuaca memberikan nilai MAPE yang lebih besar dibandingkan proses klasifikasi dikarenakan pada proses ini target memiliki variasi yang besar. Variasi yang besar ini menyulitkan jaringan ELM untuk menentukan bobot yang tepat. Berbeda halnya dengan proses klasifikasi dan penelitian lain seperti yang termuat dalam (Huang dkk, 2006) dan (Najar, A.M. dkk, 2018), dimana targetnya memiliki variasi yang kecil.

BAB 5

KESIMPULAN DAN SARAN

Pada bab ini disampaikan kesimpulan dan saran yang diperoleh dari hasil penelitian tentang prediksi tingkat risiko wabah demam berdarah berdasarkan keadaan cuaca menggunakan Extreme Learning Machine.

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang diuraikan pada bab sebelumnya, dapat ditarik kesimpulan sebagai berikut:

1. Untuk Melakukan prediksi tingkat risiko wabah demam berdarah berdasarkan keadaan cuaca, perlu dilakukan klasifikasi tingkat risiko wabah demam berdarah berdasarkan keadaan cuaca. Pada penelitian ini arsitektur ELM terbaik yang dapat digunakan adalah ELM dengan fungsi aktivasi sigmoid bipolar dan 90 *hidden neuron*. Pengenalan Pola dengan arsitektur ini memberikan performa yang sangat baik, karena mampu mengenali setiap kelas tingkat risiko secara tepat.
2. Model jaringan syaraf tiruan Extreme Learning Machine untuk peramalan cuaca dapat dibangun dengan cara terlebih dahulu menentukan banyaknya input neuron dan *hidden neuron*. Selanjutnya melakukan proses training dan testing untuk menentukan arsitektur yang memberikan performa terbaik. Pada penelitian ini performa terbaik untuk untuk setiap variabel cuaca yang menjadi prediktor pada proses prediksi prediksi tingkat risiko wabah demam berdarah adalah sebagai berikut:
 - a. Temperatur Maksimum
Arsitektur terbaik untuk peramalan Temperatur Maksimum adalah ELM yang menggunakan fungsi aktivasi sigmoid bipolar dengan 20 *hidden neuron* dan 12 neuron input
 - b. Temperatur Minimum
Arsitektur terbaik untuk peramalan Temperatur Minimum adalah ELM yang menggunakan fungsi aktivasi sigmoid bipolar dengan 25 *hidden neuron* dan 12 neuron input.

c. Kelembaban Minimum

Arsitektur terbaik untuk peramalan kelembaban Minimum adalah ELM yang menggunakan fungsi aktivasi sigmoid bipolar dengan 20 *hidden neuron* dan 6 neuron input.

d. Kelembaban rata-rata

Arsitektur terbaik untuk peramalan kelembaban Minimum adalah ELM yang menggunakan fungsi aktivasi sigmoid biner dengan 10 *hidden neuron* dan 4 neuron input.

3. Model jaringan syaraf tiruan ELM dengan arsitektur yang dijelaskan di atas dapat digunakan dengan baik untuk prediksi tingkat risiko wabah demam berdarah dengan error (MAPE) sebesar 13.372%. Nilai MAPE ini menunjukkan bahwa model yang dibangun memiliki akurasi yang cukup baik. Sehingga dapat disimpulkan bahwa model yang telah dibangun ini dapat digunakan untuk melakukan prediksi tingkat risiko wabah demam berdarah disuatu daerah.

5.2 Saran

Pada penelitian ini baik proses klasifikasi atau pengenalan pola hubungan cuaca dan tingkat risiko wabah demam berdarah dengue dan proses peramalan cuaca hanya menggunakan metode *extreme learning machine*. Pada penelitian selanjutnya dapat dicoba untuk menggunakan metode lain, khususnya pada bagian peramalan cuaca.

Selain itu, pada penelitian ini variabel input yang digunakan terbatas pada keadaan cuaca sehingga tingkat risiko wabah DBD hanya diukur berdasarkan keadaan cuaca. Pada kenyataannya, selain cuaca masih ada variabel-variabel lain yang mempengaruhi tingkat risiko wabah demam berdarah, oleh karena itu untuk penelitian selanjutnya dapat dipertimbangkan untuk menambahkan faktor-faktor lain selain keadaan cuaca sebagai variabel input.

DAFTAR PUSTAKA

- Aldrian, E., Karmini, M., dan Budiman, (2011), *Adaptasi dan Mitigasi Perubahan Iklim di Indonesia*, Pusat Perubahan Iklim dan Kualitas Udara Kedeputian Bidang Klimatologi BMKG, Jakarta
- Apriliana (2017), *Pengaruh Iklim Terhadap Kejadian Demam Berdarah Dengue di Kota Bandar Lampung, Provinsi Lampung*, CDK. Vol .44, No. 3, 2017, 172-175.
- Ariestyani, M.,C., Adikara, P.,P., Perdana, R.,S., (2018).*Klasifikasi Penyimpangan Tumbuh Kembang Anak Menggunakan Metode Extreme Learning Machine (ELM)*, Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol.2, No.4,2018, 1620-1629.
- Banu, S., Hu, W., Guo, Y., Hurst, C., Tong, S., (2014), *Proecting the Impact of Climate Change on Dengue Transmission in Dhaka, Bangladesh*, Enviromental International. Vol .63, 2014, 137-142.
- Departemen Kesehatan RI, (1998), *Petunjuk Teknis, Penemuan, Pertologan, dan Pelaporan Demam Berdarah Dengue*, Direktorat Jendral Pemberantasan Penyakit Menular dan Penyehatan Lingkungan, Depkes RI, Jakarta.
- Direktorat Jenderal Pengendalian Perubahan Iklim (2016), *Perubahan Iklim, Perjanjian Paris, dan Nationally Determined Contribution*, Kementerian Lingkungan Hidup dan Kehutanan, Jakarta
- Eberhart R.C., dan Shi, Y., (2007), *Computational Intelligence Concepts to Implementations*, Morgan Kaufmann Publishers, USA.
- Fauset, L., (1994), *Fundamentasls of Neural Networks*, Prentice Hall PTR, New Jersey.
- Fitriyani, (2007), *Penentuan Wilayah Rawan Demam Berdarah Dengue di Indonesia dan Analisis pengaruh pola hujan terhadap tingkat serangan (Studi Kasus: Kabupaten Indramayu)*, Skripsi, IPB.
- Hasanah, U, (2007), *Analisis Hubungan Cuaca dan Jumlah Penderita Demam Berdarah Dengue (DBD) dengan fungsi transfer*, Skripsi, IPB.
- Huang, GB., Zhu, QY., Siew, CK., (2004), "Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks", *Proceeding of International Joint Conference on Neural Networks (IJCNN2004)*,Budapest

- Huang, GB., Zhu, QY., Siew, CK., (2006), *Extreme Learning Machine : Theory and Application*, Neurocomputing. Vol.70, 2006, 489-501.
- Irawan M.,I, (2015), *Dasar-dasar Jaringan Syaraf Tiruan*, ITS Press, Surabaya.
- Kementerian Kesehatan RI, (2010), *Demam Berdarah Dengue*, Buletin Epidemiologi, Kemenkes RI, Jakarta.
- Kementerian Kesehatan RI, (2011-2016), *Profil Kesehatan Indonesia Tahun 2011-2016*, Kemenkes RI, Jakarta.
- Kementerian Kesehatan RI, (2016b), *Situasi DBD di Indonesia*, Infodatin, Kemenkes RI, Jakarta.
- Kusumadewi, S.,(2004)*Membangun Jaringan Syaraf Tiruan Menggunakan Matlab dan Excel Link*, Graha Ilmu, Yogyakarta
- McMichael A.,J dkk, (2003), *Climate Change and Human Health Risks and responses*, World Health Organization, Geneva.
- Najar, A.M., Irawan, M.I., Adzkiya, D., (2018), "Extreme Learning Machine Method For Dengue Hemorrhagic Fever Outbreak Risk Level", *Proceeding of IEEE International Conference on Smart Computing and Electronic Enterprise(ICSCEE)*,Kuala Lumpur
- Pangaribuan J.J., (2016), *Mendiagnosis Penyakit Diabetes Melitus dengan Menggunakan Metode Extreme Learning Machine*, Jurnal ISD. Vol.2, No.2, 2016, 32-40.
- Rofiq, M.,A., (2017), *Peramalan Komoditas Strategis Pertanian Cabai Menggunakan Backpropagation Neural Network*, Skripsi, ITS Surabaya.
- Sintorini, M.M., (2007), *Pengaruh Iklim terhadap Kasus Demam Berdarah Dengue*, Jurnal Kesehatan Masyarakat Nasional. Vol .2, No.1, 2007, 11-18.
- Syed A., dan Aggarwa, S.K., (2016), *Wind Power Forecasting Using Extreme Learning Machine*, IJRSI . Vol .3, Issue.3, 2007, 33-37.

LAMPIRAN 1

Tabel r untuk df = 101 - 150

df = (N-2)	Tingkat signifikansi untuk uji satu arah				
	0.05	0.025	0.01	0.005	0.0005
	Tingkat signifikansi untuk uji dua arah				
	0.1	0.05	0.02	0.01	0.001
101	0.1630	0.1937	0.2290	0.2528	0.3196
102	0.1622	0.1927	0.2279	0.2515	0.3181
103	0.1614	0.1918	0.2268	0.2504	0.3166
104	0.1606	0.1909	0.2257	0.2492	0.3152
105	0.1599	0.1900	0.2247	0.2480	0.3137
106	0.1591	0.1891	0.2236	0.2469	0.3123
107	0.1584	0.1882	0.2226	0.2458	0.3109
108	0.1576	0.1874	0.2216	0.2446	0.3095
109	0.1569	0.1865	0.2206	0.2436	0.3082
110	0.1562	0.1857	0.2196	0.2425	0.3068
111	0.1555	0.1848	0.2186	0.2414	0.3055
112	0.1548	0.1840	0.2177	0.2403	0.3042
113	0.1541	0.1832	0.2167	0.2393	0.3029
114	0.1535	0.1824	0.2158	0.2383	0.3016
115	0.1528	0.1816	0.2149	0.2373	0.3004
116	0.1522	0.1809	0.2139	0.2363	0.2991
117	0.1515	0.1801	0.2131	0.2353	0.2979
118	0.1509	0.1793	0.2122	0.2343	0.2967
119	0.1502	0.1786	0.2113	0.2333	0.2955
120	0.1496	0.1779	0.2104	0.2324	0.2943
121	0.1490	0.1771	0.2096	0.2315	0.2931
122	0.1484	0.1764	0.2087	0.2305	0.2920
123	0.1478	0.1757	0.2079	0.2296	0.2908
124	0.1472	0.1750	0.2071	0.2287	0.2897
125	0.1466	0.1743	0.2062	0.2278	0.2886
126	0.1460	0.1736	0.2054	0.2269	0.2875
127	0.1455	0.1729	0.2046	0.2260	0.2864
128	0.1449	0.1723	0.2039	0.2252	0.2853
129	0.1443	0.1716	0.2031	0.2243	0.2843
130	0.1438	0.1710	0.2023	0.2235	0.2832
131	0.1432	0.1703	0.2015	0.2226	0.2822
132	0.1427	0.1697	0.2008	0.2218	0.2811
133	0.1422	0.1690	0.2001	0.2210	0.2801
134	0.1416	0.1684	0.1993	0.2202	0.2791
135	0.1411	0.1678	0.1986	0.2194	0.2781
136	0.1406	0.1672	0.1979	0.2186	0.2771
137	0.1401	0.1666	0.1972	0.2178	0.2761
138	0.1396	0.1660	0.1965	0.2170	0.2752
139	0.1391	0.1654	0.1958	0.2163	0.2742
140	0.1386	0.1648	0.1951	0.2155	0.2733
141	0.1381	0.1642	0.1944	0.2148	0.2723
142	0.1376	0.1637	0.1937	0.2140	0.2714
143	0.1371	0.1631	0.1930	0.2133	0.2705
144	0.1367	0.1625	0.1924	0.2126	0.2696
145	0.1362	0.1620	0.1917	0.2118	0.2687

LAMPIRAN 2
Kasus DBD di DKI Jakarta Tahun 2008 Hingga 2016

Tahun		Banyaknya Kasus DBD							
		Pusat	Utara	Barat	Selatan	Timur	Kep. Seribu	DKI	AI
2008	1	441	487	436	944	774	0	3082	33.69712
	2	303	381	380	763	801	0	2628	28.7333
	3	363	394	475	691	924	0	2847	31.12775
	4	516	486	674	819	1269	0	3764	41.15379
	5	556	620	747	940	1910	0	4773	52.18572
	6	419	502	488	760	1382	0	3551	38.82495
	7	179	269	311	438	608	0	1805	19.73501
	8	124	191	208	270	291	0	1084	11.85194
	9	91	137	182	210	195	0	815	8.910823
	10	117	149	209	274	205	0	954	10.43058
	11	121	171	170	329	240	0	1031	11.27246
	12	228	265	244	625	411	1	1774	19.39607
2009	1	337	571	353	948	911	1	3121	33.83931
	2	350	588	343	764	1029	0	3074	33.32972
	3	538	1048	510	815	1250	0	4161	45.11547
	4	492	847	590	873	1487	0	4289	46.50331
	5	369	629	430	1067	1197	1	3693	40.0412
	6	325	567	416	923	754	0	2985	32.36474
	7	336	511	331	668	860	3	2709	29.37222
	8	150	284	178	379	391	2	1384	15.00596
	9	71	116	90	182	220	0	679	7.36203
	10	66	125	70	142	163	0	566	6.136832
	11	48	98	72	137	191	0	546	5.919983
	12	98	188	130	289	324	0	1029	11.15689
2010	1	212	321	238	686	662	0	2119	22.05503
	2	279	475	359	673	820	1	2607	27.13424
	3	424	723	569	802	1152	0	3670	38.19818
	4	444	682	614	798	1044	0	3582	37.28226
	5	273	391	413	519	764	0	2360	24.56341
	6	178	327	370	424	494	0	1793	18.66195
	7	247	319	433	513	588	0	2100	21.85727
	8	345	366	444	567	654	0	2376	24.72994
	9	311	381	388	466	524	1	2071	21.55543
	10	272	249	322	449	476	0	1768	18.40174
	11	337	285	376	543	777	0	2318	24.12626
	12	274	265	334	410	654	1	1938	20.17114
2011	1	207	296	290	354	604	1	1752	17.71138
	2	118	232	173	244	460	0	1227	12.40403
	3	133	332	200	213	334	5	1217	12.30294
	4	127	217	122	185	222	0	873	8.825364
	5	92	236	120	128	211	0	787	7.95597
	6	114	257	123	144	251	0	889	8.987112
	7	115	245	132	192	240	1	925	9.351045
	8	85	220	139	116	244	2	806	8.148045
	9	73	151	106	96	145	0	571	5.772375
	10	62	134	95	114	134	0	539	5.448879
	11	55	83	112	103	142	0	495	5.004073
	12	83	142	169	156	169	3	722	7.298869

Tahun		Banyaknya Kasus DBD							
		Pusat	Utara	Barat	Selatan	Timur	Kep. Seribu	DKI	AI
2012	1	101	232	234	291	354	0	1212	12.28942
	2	157	301	300	311	472	1	1542	15.63555
	3	202	279	302	385	615	3	1786	18.10966
	4	168	324	250	331	542	2	1617	16.39604
	5	167	306	275	288	535	0	1571	15.92961
	6	148	212	226	323	384	0	1293	13.11075
	7	112	150	199	229	297	0	987	10.00797
	8	44	98	133	163	161	1	600	6.083873
	9	41	54	94	78	95	1	363	3.680743
	10	44	70	80	50	76	0	320	3.244733
	11	39	66	69	81	74	3	332	3.36641
	12	71	93	107	174	197	1	643	6.519884
2013	1	123	152	238	361	460	0	1334	13.38021
	2	138	273	227	314	447	0	1399	14.03217
	3	178	254	347	269	605	0	1653	16.57983
	4	258	446	413	343	727	0	2187	21.93592
	5	213	553	343	374	670	1	2154	21.60493
	6	175	424	277	406	632	1	1915	19.20772
	7	193	366	278	558	782	0	2177	21.83562
	8	163	374	296	596	743	1	2173	21.7955
	9	124	241	217	402	464	2	1450	14.54371
	10	75	217	168	240	256	1	957	9.598846
	11	69	207	146	217	226	1	866	8.686103
	12	74	214	151	316	279	0	1034	10.37117
2014	1	137	339	253	576	512	9	1826	18.12351
	2	204	379	337	573	594	1	2088	20.72393
	3	342	501	503	697	767	2	2812	27.90981
	4	324	503	598	665	726	2	2818	27.96936
	5	244	409	411	510	652	2	2228	22.11346
	6	86	220	354	246	286	0	1192	11.8309
	7	113	326	280	310	374	0	1403	13.92513
	8	103	378	314	414	367	2	1578	15.66205
	9	87	241	171	246	242	0	987	9.796225
	10	51	140	108	183	162	0	644	6.391863
	11	33	108	90	64	120	0	415	4.11898
	12	36	84	125	88	114	0	447	4.436588
2015	1	79	164	178	246	216	0	883	8.67564
	2	101	272	202	340	248	1	1164	11.43652
	3	180	345	335	317	442	0	1619	15.90698
	4	220	666	391	325	544	6	2152	21.1438
	5	140	486	327	372	519	5	1849	18.16677
	6	95	338	199	279	376	1	1288	12.65484
	7	48	201	145	140	225	1	760	7.467142
	8	19	156	70	72	115	0	432	4.244481
	9	31	190	58	52	109	2	442	4.342732
	10	27	184	61	55	115	2	444	4.362383
	11	29	142	44	55	121	1	392	3.851473
	12	33	163	79	117	149	0	541	5.315426

Tahun		Banyaknya Kasus DBD							
		Pusat	Utara	Barat	Selatan	Timur	Kep. Seribu	DKI	AI
2016	1	220	392	324	569	516	0	2021	19.66407
	2	357	776	767	1013	1149	4	4066	39.56166
	3	615	992	1045	1361	1845	1	5859	57.00732
	4	694	1343	1605	1353	2277	1	7273	70.76536
	5	342	817	834	910	1425	0	4328	42.11088
	6	210	505	616	707	1053	2	3093	30.09449
	7	179	317	505	579	690	4	2274	22.12573
	8	205	321	690	560	685	2	2463	23.96467
	9	172	293	567	445	573	2	2052	19.9657
	10	159	260	552	501	628	1	2101	20.44246
	11	173	286	536	461	815	1	2272	22.10627
	12	137	254	445	406	619	2	1863	18.12675

LAMPIRAN 3

Keadaan Cuaca DKI Jakarta Tahun 2005-2016

Tahun		Suhu			Kelembaban Relatif			Curah Hujan
		Maks	Min	Rerata	Maks	Min	Rerata	
2005	1	33.20	24.10	27.50	94.00	54.00	79.00	392.50
	2	33.40	23.80	27.80	95.00	55.00	79.00	351.60
	3	33.60	23.40	28.10	98.00	54.00	77.50	422.60
	4	35.00	24.50	29.00	91.00	49.00	73.00	105.40
	5	35.00	24.60	29.20	92.00	49.00	73.00	93.30
	6	34.60	24.20	28.90	93.00	49.00	74.00	134.10
	7	34.00	24.20	28.50	91.00	45.00	72.00	160.60
	8	34.80	24.20	28.50	92.00	45.00	71.00	39.10
	9	35.00	24.00	29.10	90.00	41.00	69.00	78.70
	10	35.30	24.20	28.60	90.00	49.00	74.00	135.70
	11	34.40	2.00	28.40	92.00	52.00	75.00	101.80
	12	34.40	24.40	28.00	92.00	50.00	78.00	377.40
2006	13	34.00	24.20	27.20	91.00	67.00	80.00	389.60
	14	33.40	24.60	27.80	92.00	77.00	79.00	350.00
	15	33.60	24.00	28.10	88.00	70.00	78.00	320.00
	16	34.00	24.00	28.40	90.00	68.00	75.00	316.10
	17	34.00	24.20	28.70	81.00	68.00	75.00	85.20
	18	34.40	23.90	28.70	74.00	61.00	71.00	30.80
	19	34.20	24.20	28.70	74.00	64.00	69.00	53.20
	20	34.20	23.60	28.30	75.00	64.00	69.00	0.00
	21	36.00	23.90	28.70	74.00	61.00	66.00	0.20
	22	35.10	24.60	29.60	73.00	52.00	66.00	10.60
	23	35.00	24.60	29.80	81.00	68.00	71.00	26.80
	24	34.50	24.50	28.00	81.00	67.00	75.00	140.00
2007	25	35.20	24.40	28.60	95.00	37.00	72.00	211.30
	26	33.50	22.20	27.10	100.00	54.00	83.00	674.90
	27	35.20	24.20	28.00	92.00	51.00	80.00	178.30
	28	34.00	24.20	28.30	93.00	56.00	79.00	165.50
	29	35.00	24.10	28.70	97.00	53.00	76.00	188.50
	30	34.00	25.00	28.50	90.00	57.00	76.00	100.70
	31	33.80	24.00	28.60	84.00	42.00	71.00	34.50
	32	34.60	24.00	28.60	92.00	47.00	67.00	66.60
	33	34.10	24.00	28.60	90.00	49.00	69.00	59.70
	34	35.20	23.00	28.60	93.00	46.00	72.00	75.60
	35	34.10	24.00	28.50	92.00	43.00	73.00	85.50
	36	32.80	23.60	27.30	98.00	46.00	80.00	512.80

Tahun		Suhu			Kelembaban Relatif			Curah Hujan
		Maks	Min	Rerata	Maks	Min	Rerata	
2008	37	31.80	25.10	28.10	90.00	65.00	76.00	226.50
	38	29.40	24.00	26.30	97.00	78.00	84.00	677.60
	39	31.20	24.90	27.40	92.00	67.00	78.00	212.40
	40	32.10	25.20	28.10	85.00	71.00	78.00	218.40
	41	33.10	25.70	28.90	77.00	61.00	71.00	25.90
	42	32.50	25.50	28.50	86.00	68.00	73.00	51.40
	43	32.90	25.10	28.40	76.00	57.00	68.00	9.50
	44	32.80	25.30	28.50	77.00	62.00	69.00	36.40
	45	33.20	25.60	28.90	78.00	64.00	70.00	97.30
	46	33.40	25.70	29.00	83.00	65.00	72.00	85.80
47	32.00	25.20	28.00	88.00	70.00	78.00	113.80	
48	31.50	25.00	27.70	87.00	72.00	78.00	154.20	
2009	49	30.30	24.50	27.10	92.00	62.00	81.00	547.90
	50	30.40	24.40	27.20	92.00	66.00	81.00	231.90
	51	32.60	25.20	28.30	85.00	67.00	76.00	141.40
	52	32.70	25.90	28.90	86.00	69.00	76.00	92.70
	53	32.60	25.60	28.50	89.00	67.00	77.00	223.40
	54	33.00	25.40	28.90	84.00	70.00	75.00	74.40
	55	32.90	25.20	28.70	76.00	56.00	68.00	10.40
	56	33.20	25.50	29.00	77.00	63.00	69.00	6.50
	57	33.80	25.70	29.40	77.00	61.00	68.00	88.30
	58	33.70	25.70	29.40	81.00	62.00	70.00	63.30
59	32.80	25.40	28.40	90.00	64.00	75.00	303.70	
60	31.90	25.70	28.50	93.00	68.00	77.00	189.10	
2010	61	31.20	24.60	27.30	94.00	71.00	82.00	354.50
	62	32.10	24.90	27.20	93.00	74.00	80.00	223.00
	63	32.70	25.40	28.30	91.00	72.00	80.00	175.80
	64	33.80	25.80	29.20	84.00	69.00	76.00	63.10
	65	33.60	25.70	28.90	91.00	71.00	78.00	112.10
	66	31.90	25.10	28.00	89.00	72.00	80.00	187.70
	67	32.00	24.90	27.80	92.00	68.00	79.00	219.20
	68	32.70	25.00	28.20	85.00	71.00	77.00	137.20
	69	32.10	24.60	27.40	93.00	73.00	81.00	256.70
	70	32.40	24.50	27.60	91.00	62.00	79.00	365.60
71	32.50	25.10	28.00	88.00	64.00	78.00	167.60	
72	31.50	24.50	27.50	86.00	69.00	78.00	142.00	
2011	73	32.60	23.40	27.30	90.00	71.00	79.00	145.60
	74	33.20	23.60	27.40	91.00	67.00	79.00	230.70
	75	34.80	24.00	27.90	81.00	69.00	76.00	147.70
	76	34.00	24.20	28.60	83.00	67.00	75.00	106.80
	77	34.40	24.00	28.80	82.00	72.00	76.00	198.90
	78	33.60	24.60	28.70	84.00	64.00	73.00	70.50
	79	33.20	24.00	28.30	83.00	65.00	74.00	18.10
	80	34.60	24.00	28.80	77.00	60.00	69.00	1.50
	81	34.80	24.00	29.00	79.00	60.00	68.00	52.60
	82	35.20	24.00	29.20	79.00	65.00	72.00	80.10
83	35.40	24.00	28.90	80.00	62.00	74.00	44.60	
84	35.00	24.00	28.90	86.00	68.00	76.00	177.00	

Tahun		Suhu			Kelembaban Relatif			Curah Hujan
		Maks	Min	Rerata	Maks	Min	Rerata	
2012	85	31.20	24.60	27.30	89.00	69.00	79.00	275.10
	86	32.10	25.00	27.90	88.00	72.00	80.00	157.90
	87	32.10	24.80	28.00	89.00	68.00	79.00	173.60
	88	32.40	25.30	28.10	87.00	72.00	80.00	196.20
	89	32.70	25.30	28.30	90.00	68.00	79.00	118.00
	90	32.70	25.00	28.40	86.00	67.00	76.00	67.20
	91	32.60	24.50	27.90	79.00	49.00	64.00	13.60
	92	33.30	24.40	28.10	89.00	43.00	66.00	2.40
	93	33.60	24.80	28.50	94.00	39.00	67.00	16.20
	94	34.00	25.20	29.10	94.00	46.00	70.00	44.30
	95	32.80	25.00	28.10	96.00	46.00	71.00	251.90
96	32.50	25.00	28.00	98.00	54.00	76.00	254.00	
2013	97	32.60	22.60	26.90	96.00	77.00	84.00	621.90
	98	34.00	22.80	27.90	88.00	71.00	80.00	146.60
	99	35.20	24.00	28.80	83.00	69.00	76.00	184.40
	100	34.60	24.00	28.70	92.00	67.00	79.00	204.30
	101	35.00	23.40	28.70	88.00	62.00	78.00	101.00
	102	33.50	23.00	27.30	94.00	68.00	80.00	256.70
	103	33.50	23.00	27.30	94.00	68.00	80.00	256.70
	104	35.00	22.40	28.60	85.00	63.00	72.00	61.40
	105	35.40	24.20	29.00	82.00	63.00	73.00	49.50
	106	35.80	22.40	29.40	87.00	65.00	72.00	110.10
	107	35.00	23.40	28.50	89.00	66.00	76.00	196.60
108	35.00	23.00	27.70	89.00	68.00	79.00	338.90	
2014	109	33.00	23.00	26.60	100.00	48.00	82.00	1075.00
	110	32.80	22.80	26.60	100.00	61.00	83.00	689.00
	111	34.40	23.90	28.00	98.00	59.00	78.00	174.00
	112	35.20	23.20	28.80	95.00	51.00	74.00	168.00
	113	35.20	25.00	29.30	95.00	53.00	73.00	47.00
	114	34.40	24.20	28.60	94.00	49.00	75.00	174.00
	115	34.20	23.40	28.00	95.00	45.00	74.00	214.00
	116	34.60	24.00	28.70	95.00	45.00	68.00	39.00
	117	37.00	24.00	29.20	88.00	31.00	62.00	0.00
	118	36.80	25.00	29.80	87.00	40.00	64.00	52.00
	119	36.00	23.80	29.40	92.00	52.00	71.00	65.00
120	34.80	24.10	28.10	95.00	47.00	75.00	211.00	
2015	121	33.55	22.98	28.26	95.00	72.00	83.00	412.00
	122	32.88	22.65	27.76	97.00	73.00	85.00	639.00
	123	34.05	23.55	28.80	89.00	75.00	82.00	221.00
	124	34.33	24.03	29.18	88.00	74.00	81.00	111.00
	125	34.20	23.63	28.91	85.00	66.00	75.00	79.00
	126	34.88	23.45	29.16	85.00	68.00	76.00	48.00
	127	34.55	23.48	29.01	77.00	64.00	70.00	1.00
	128	34.40	22.40	28.40	77.00	61.00	69.00	12.00
	129	34.98	23.75	29.36	75.00	60.00	67.00	5.00
	130	36.00	24.43	30.21	75.00	55.00	65.00	6.00
	131	35.15	24.08	29.61	83.00	68.00	75.00	103.00
132	34.48	23.10	28.79	88.00	68.00	78.00	194.00	

Tahun		Suhu			Kelembaban Relatif			Curah Hujan
		Maks	Min	Rerata	Maks	Min	Rerata	
2016	133	34.00	24.30	28.70	92.00	72.00	80.00	136.60
	134	32.60	24.00	27.80	92.00	71.00	82.80	451.75
	135	33.60	24.40	28.60	89.00	74.00	81.00	293.50
	136	34.70	24.80	29.40	86.00	72.00	77.00	192.25
	137	35.20	25.00	29.30	86.00	72.00	78.40	112.05
	138	35.00	23.40	28.80	85.00	69.00	76.10	186.40
	139	35.00	24.00	28.50	92.00	69.00	77.20	188.60
	140	34.40	24.00	28.50	92.00	59.00	76.10	217.45
	141	35.20	24.20	28.70	89.00	67.00	76.40	220.50
	142	33.80	24.20	28.40	93.00	66.00	77.20	172.75
	143	34.20	24.70	28.60	89.00	68.00	76.80	152.40
144	34.40	24.00	28.50	89.00	67.00	75.30	41.70	

LAMPIRAN 4

Source Code

```
import numpy as np
import time
from openpyxl import load_workbook
import pandas as pd
import matplotlib.pyplot as plt
from scipy.linalg import pinv2

def normFunc(dataMentah, skalaMax, skalaMin):
    (m,n)=dataMentah.shape
    global x_max
    global x_min
    x_max = np.array(np.zeros([n, 1]))
    x_min = np.array(np.zeros([n, 1]))
    for i in range(0, n):
        x_max[i] = max(dataMentah[:, i])
        x_min[i] = min(dataMentah[:, i])
    x_norm = np.array(np.zeros([m, n]))
    for j in range(0, m):
        for j2 in range(0, n):
            x_norm[j, j2] = (((skalaMax-skalaMin) * (dataMentah[j, j2] - x_min[j2])) / (x_max[j2] -
x_min[j2])) + skalaMin
    return x_norm

def denorFunc(dataNorm, skalaMax, skalaMin):
    (m, n) = dataNorm.shape
    x_denorm=np.array(np.zeros([m,n]))
    for j in range(0, m):
        for j2 in range(0, n):
            x_denorm[j, j2] = (((x_max[j2]-x_min[j2]) * (dataNorm[j, j2] - skalaMin)) / (skalaMax -
skalaMin)) + x_min[j2]
    return x_denorm

def sigBiner(x,sigma):
    return (1/(1+ np.exp(-(sigma*x))))

def sigBipolar(x,sigma):
    return ((1 - np.exp(-(sigma*x)))/(1 + np.exp(-(sigma*x))))

def pseudoinvers(A):
    b_temp = np.transpose(A)
    b_temp2 = np.dot(b_temp, A)
    b_temp3 = np.linalg.inv(b_temp2)
    return np.dot(b_temp3, b_temp)
```

```

def RMSE(prediksi, aktual):
    return (np.sqrt(((prediksi - aktual) ** 2).mean()))

def MAPE(prediksi, aktual):
    return (np.mean(np.abs((aktual - prediksi)/aktual)) * 100)

def MAE(prediksi, aktual):
    return (np.mean(np.abs(aktual-prediksi)))

def elmlatih(datainput,target,hidden):
    (m,n)=np.shape(datainput)
    b=np.random.randn(1,hidden)
    w=np.random.randn(n,hidden)
    z=np.array(np.zeros([m,hidden]))
    for i in range(len(datainput)):
        z[i]=np.dot(datainput[i],w)+ b

    H=sigBipolar(z,1)
    T=target
    (m2,n2)=np.shape(H)
    if m2==n2:
        H_inv=np.linalg.inv(H)
    else:
        H_inv= pinv2(H)

    beta=np.dot(H_inv,np.transpose(T))
    return (beta,w,b)

def elmtes(data, w,b,beta):
    z=np.dot(data,w)+ b
    H_test=sigBipolar(z,1)
    T=np.dot(H_test,beta)
    return T

## Klasifikasi
iklim=load_workbook('data3.xlsx')
iklim=iklim.get_sheet_by_name('Sheet2')
m=iklim.max_row
n=iklim.max_column
data2=np.array(np.zeros([m,n]))
for i in range (0,m):
    for j in range (0,n):
        data2[i,j]=iklim.cell(row=i+ 1,column=j+ 1).value
data2=np.array(data2)

data=data2
add=1000
point2=np.array(np.zeros([add,n]))

```



```

for i in range(add):
    ri= np.random.randint(len(data))
    point=data[ri]
    point2[i]=point

target=point2[:,n-1]
varcuaca=point2[:,0:n-1]

for i in range (0,len(target)):
    if target[i]<1.75:
        target[i]=1
    elif target[i]>4.58:
        target[i]=3
    else:
        target[i]=2

datalatih=varcuaca[:750]
datatesting=varcuaca[750:1000]
targetlatih=target[:750]
targettesting=target[750:1000]
#normalisasi
cuaca=normFunc(datalatih,1,0)
cuaca2=normFunc(datatesting,1,0)

#Latih
best_error=1000
best_b=0
best_w=0
best_beta=0
for i in range (0,1000):
    mulai=time.time()
    (beta,w,b)=elmlatih(cuaca,targetlatih,90)
    perantara=time.time()
    T=elmtes(cuaca,w,b,beta)
    stop=time.time()
    error=MAE(T,targetlatih)
    if error < best_error:
        best_error=error
        best_b=b
        best_w=w
        best_beta=beta
waktu_latih=perantara-mulai
waktu_testing=stop-perantara

T1=elmtes(cuaca,best_w,best_b,best_beta)
eror_MAE1=MAE(T1,targetlatih)
eror_MAPE1=MAPE(T1,targetlatih)

```

```

#testing
T2=elmtes(cuaca2,best_w,best_b,best_beta)
eror_MAE=MAE(T2,targettesting)
eror_MAPE=MAPE(T2,targettesting)
eror=[eror_MAE1,eror_MAPE1,eror_MAE,eror_MAPE]
waktu=[waktu_latih,waktu_testing]

## Peramalan Keadaan Cuaca
iklim=load_workbook('Iklim DKI Jakarta.xlsx')
iklim=iklim.get_sheet_by_name('edited2')
m=iklim.max_row
n=iklim.max_column
datacuaca=np.array(np.zeros([m,n]))
for i in range (0,m):
    for j in range (0,n):
        datacuaca[i,j]=iklim.cell(row=i+ 1,column=j+ 1).value

datacuaca=np.array(datacuaca)

dimensi
dim=13

#siapkan data latih
Tmax_temp=datacuaca[:,0]

Tmax=np.array(np.zeros([len(Tmax_temp)-dim+ 1,dim]))
for i in range (len(Tmax)):
    for j in range (0,dim):
        Tmax[i,j]=Tmax_temp[i+ j]

(u,v)=np.shape(Tmax)

data=Tmax
varInput=data[:,0:v-1]
target=data[:,v-1]

#normalisasi
varinput=normFunc(varInput,1,0)

#latih
Tmax_error=100000
Tmax_b=0
Tmax_w=0
Tmax_beta=0
for i in range (0,1000):
    mulai=time.time()
    (beta,w,b)=elmlatih(varinput[:,u- 12],target[:,u- 12],20)
    perantara=time.time()

```

```

T=elmtes(varinput[:u-12],w,b,beta)
error=MAE(T,target[:u-12])
stop=time.time()
if error < Tmax_error:
    Tmax_error=error
    Tmax_b=b
    Tmax_w=w
    Tmax_beta=beta
waktu_latih=perantara-mulai
waktu_testing=stop-perantara

T_max=elmtes(varinput[:u-12],Tmax_w,Tmax_b,Tmax_beta)
eror_MAE1 = MAE(T_max,target[:u-12])
eror_MAPE1 = MAPE(T_max,target[:u-12])

#Testing
T_maks=elmtes(varinput[u-12:u],Tmax_w,Tmax_b,Tmax_beta)
eror_MAE = MAE(T_maks,target[u-12:u])
eror_MAPE = MAPE(T_maks,target[u-12:u])
eror_Tmax=[eror_MAE1,eror_MAPE1,eror_MAE,eror_MAPE]
waktu_Tmax=[waktu_latih,waktu_testing]

```

LAMPIRAN 5

Performa Jaringan ELM Untuk Proses Klasifikasi Berdasarkan Fungsi Aktivasi dan Banyaknya Hidden Neuron

Hidden Neuron	Sigmoid Biner		Sigmoid Bipolar	
	MAE	MAPE	MAE	MAPE
5	0.12133	5.04509	0.11033	4.78647
10	0.14028	5.44848	0.1118	4.82752
15	0.12179	4.79355	0.10108	4.19319
20	0.1035	4.00894	0.10444	4.11351
25	0.08423	3.27321	0.08225	3.14756
30	0.0819	3.11699	0.09026	3.53009
35	0.07511	2.93646	0.06783	2.58229
40	0.06291	2.47463	0.07129	2.80401
45	0.05986	2.34554	0.05646	2.18686
50	0.05708	2.26958	0.05157	2.01287
55	0.05282	2.08405	0.05232	2.00616
60	0.04917	1.93445	0.04495	1.75503
65	0.04437	1.76615	0.04129	1.60247
70	0.04393	1.75369	0.04003	1.56464
75	0.0399	1.59276	0.03523	1.415
80	0.03865	1.54676	0.03777	1.42821
85	0.04047	1.59153	0.03859	1.44563
90	0.03861	1.51912	0.03419	1.25172
95	0.04179	1.54636	0.03645	1.33323
100	0.08343	2.96198	0.05177	1.85267
105	0.05966	2.16922	0.1244	4.46418
110	0.14741	5.32952	0.35908	12.3289
115	0.2705	9.35419	0.38902	13.5587
120	0.27052	9.43875	0.40383	14.3766
125	0.24567	8.71772	0.45338	16.3221
130	0.32383	11.4031	0.72349	26.3145
135	0.62571	21.3956	0.62575	22.7425
140	0.46825	16.2112	0.61596	21.4967
145	0.61281	21.0111	1.41458	48.8162
150	0.68064	23.8117	1.1491	39.9658
155	0.56599	19.4987	1.17303	40.4979
160	0.58589	20.4877	0.8629	30.0756
165	0.92229	31.9954	1.63635	59.2438
170	0.91231	31.5019	1.53143	52.7671
175	0.77045	26.6397	1.67678	58.4041
180	1.24505	43.1338	1.12412	39.1667
185	1.0007	36.0737	1.53945	53.3235
190	1.4044	50.4991	2.3244	85.0431
195	1.32874	46.7514	2.36885	83.4489
200	0.52293	18.4268	1.82158	62.0707

LAMPIRAN 6

Performa Jaringan ELM Untuk Proses Peramalan Cuaca Berdasarkan Fungsi Aktivasi dan Banyaknya Hidden Neuron

Performa Jaringan ELM untuk Peramalan Temperatur Maksimum dengan 4 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	0.608539	1.82904286	0.576844	1.682074	0.61001	1.833179	0.584439	1.704916
10	0.59872	1.79882324	0.528181	1.537661	0.591945	1.775446	0.60265	1.763179
15	0.583447	1.75202874	0.529883	1.542654	0.568482	1.70299	0.600783	1.745139
20	0.570938	1.71528298	0.507669	1.478271	0.553469	1.65435	0.62929	1.831268
25	0.543889	1.62872269	0.545715	1.594254	0.544196	1.626371	0.63776	1.855725
30	0.487233	1.45665717	0.630387	1.836852	0.5009	1.492928	0.788937	2.310107
35	0.493696	1.47265123	0.64407	1.880344	0.484721	1.440967	0.668474	1.950807
40	0.46891	1.39731737	0.578945	1.688285	0.451453	1.343163	0.800239	2.340548
45	0.452556	1.34931247	0.600432	1.751003	0.426165	1.26347	1.696443	5.007971
50	0.416848	1.23858321	0.72829	2.12241	0.398991	1.181691	1.186854	3.475315
55	0.363369	1.07848788	0.671361	1.958673	0.358008	1.063541	1.850692	5.48237
60	0.369159	1.096451	0.608607	1.783752	0.325023	0.96343	1.397461	4.099635
65	0.342303	1.01636064	0.731198	2.133713	0.320801	0.949951	2.192851	6.454133
70	0.323855	0.96114186	0.754269	2.206369	0.292217	0.865414	4.348618	12.83372
75	0.292193	0.863731	0.729617	2.125286	0.284058	0.841407	2.245431	6.604778
80	0.279777	0.83053635	0.643882	1.876712	0.253865	0.747015	4.832528	14.30818
85	0.285604	0.84728241	0.882747	2.578861	0.270703	0.800701	5.161237	15.28405
90	0.278423	0.82734608	0.703409	2.050644	0.254796	0.753198	4.737034	14.02601
95	0.28204	0.83503842	0.995671	2.905799	0.472499	1.415848	5.625653	16.58162
100	0.327305	0.97322757	1.894639	5.485222	1.161535	3.492284	6.944691	20.47947
105	0.47174	1.39189458	1.182764	3.436276	1.740957	5.154395	10.59302	31.4284
110	1.573516	4.69415748	3.186172	9.307832	2.996017	9.041243	12.58531	37.39937
115	1.718908	5.13810121	4.692341	13.61006	3.645413	10.92732	19.22129	56.98704
120	3.680038	10.8868702	7.491237	21.81349	3.976159	11.96474	14.59594	42.9387
125	4.272361	12.79895	4.606633	13.43355	4.792443	14.21981	21.17285	62.21663
130	4.566616	13.5947826	6.267878	18.10228	3.501124	10.43211	12.9026	37.97992
135	5.621634	16.7160938	6.217352	18.10392	2.638149	7.93455	57.8315	171.5609
140	7.321265	21.862202	9.154897	26.73538	3.754498	11.14791	11.9108	34.80083
145	6.851319	20.2906876	11.78585	34.32768	5.355003	15.99898	25.63687	75.28228
150	13.72743	41.4924471	13.04147	37.86501	5.719049	17.14924	77.29377	231.2713
155	9.050636	27.0374368	11.12957	32.35464	7.099976	21.06506	12.43066	36.57575
160	12.11176	36.3663575	11.65313	34.03933	5.357616	16.04339	49.24543	146.9483
165	10.90999	32.7930408	12.76526	37.15746	7.703377	23.05011	86.69933	255.3616
170	10.6855	32.0029899	19.0069	55.0866	5.641941	16.81979	18.88263	55.50285
175	19.93366	59.3053484	26.42156	76.88425	8.30199	25.06828	32.58287	96.89532
180	12.39504	36.4370748	17.70786	51.39102	9.407243	28.40708	173.6086	519.9364
185	21.05898	63.4636202	12.41926	36.25654	10.5325	31.40493	33.02978	97.63287
190	18.09757	54.5257479	17.50124	51.14187	11.94162	36.33886	18.14907	53.8576
195	17.8775	54.0144686	21.88237	63.25307	11.49021	33.97763	37.71514	111.3552
200	11.19839	33.72529	9.882984	28.9014	11.93338	35.57423	48.5044	143.5182

Performa Jaringan ELM untuk Peramalan Temperatur Maksimum dengan 6 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	0.638877	1.9195354	0.526362	1.535179	0.625888	1.882004	0.562427	1.636854
10	0.611538	1.83315901	0.474173	1.377544	0.601974	1.807644	0.537613	1.566418
15	0.601258	1.80815885	0.467545	1.353825	0.584926	1.755023	0.551901	1.608632
20	0.569902	1.70728655	0.449585	1.305991	0.562956	1.685777	0.521103	1.512166
25	0.549665	1.64634685	0.489704	1.422824	0.538345	1.610063	0.568167	1.644877
30	0.5092	1.51952703	0.490142	1.419342	0.514092	1.534398	0.626436	1.834438
35	0.516444	1.53961354	0.471116	1.370489	0.507238	1.507758	0.960795	2.805441
40	0.484405	1.44180508	0.535346	1.557298	0.475562	1.412617	0.840474	2.456265
45	0.463975	1.38256433	0.525582	1.529436	0.439054	1.305668	1.027742	3.026358
50	0.439611	1.31045139	0.44631	1.298506	0.416325	1.238149	1.012002	2.980581
55	0.410243	1.21990308	0.567539	1.654098	0.378821	1.124867	1.360454	3.990808
60	0.373788	1.1115736	0.574464	1.67813	0.349227	1.036398	1.182844	3.459892
65	0.360669	1.07425945	0.59638	1.74188	0.342788	1.01569	1.300512	3.80703
70	0.339633	1.0092758	0.604001	1.765173	0.302962	0.897279	1.307137	3.846986
75	0.315607	0.939431	0.586933	1.715578	0.296239	0.877932	1.372513	4.01945
80	0.293049	0.87093044	0.623841	1.821173	0.260174	0.771924	2.051595	6.050633
85	0.266076	0.78946556	0.564896	1.653594	0.203025	0.601513	1.510402	4.461861
90	0.236046	0.69737643	0.838676	2.432654	0.171477	0.507731	2.247976	6.585899
95	0.209087	0.61659575	0.624385	1.822214	0.144895	0.430127	4.13191	12.06099
100	0.177376	0.52244952	0.899881	2.62529	0.086537	0.256106	5.995459	17.54073
105	0.141192	0.41849183	1.223015	3.566927	0.066875	0.198015	6.876784	20.52667
110	0.11032	0.32623194	2.018045	5.878007	0.024016	0.071051	9.595848	28.08024
115	0.059932	0.17880869	2.655737	7.716638	0.40415	1.197515	10.7409	31.66886
120	0.030656	0.09029719	1.962602	5.714347	2.726977	8.159283	14.42942	42.49439
125	0.004853	0.01452745	2.521539	7.389841	3.445194	10.35755	10.94744	32.36045
130	2.898705	8.59121774	6.752378	19.69972	4.52373	13.58387	11.58614	34.00496
135	4.52239	13.5150427	5.385574	15.89084	2.601846	7.820769	13.37154	39.45387
140	9.23663	27.7815509	10.06468	29.45538	4.047019	12.12227	10.56091	31.29663
145	8.76786	26.3679698	9.858263	28.66478	7.495273	22.38685	11.85115	34.77594
150	9.769541	29.1260409	12.53365	36.51194	7.796132	23.22167	18.54708	54.28917
155	10.16489	30.4287826	8.091909	23.58487	7.010842	20.93507	17.86712	52.83018
160	10.34588	30.9178475	11.34871	33.03835	7.253466	21.79979	6.809057	19.81312
165	13.90523	41.6582606	14.96148	43.34257	11.11472	33.37818	13.47192	39.20423
170	10.80661	32.2449789	19.98658	58.83194	15.36749	45.56584	27.57899	81.16692
175	19.84916	59.3774694	43.77216	127.0986	11.61153	35.16693	16.66728	48.95292
180	17.02777	50.8396592	19.27423	56.08289	12.51161	37.6673	38.05444	112.0967
185	19.60202	58.3096046	24.30323	70.86843	16.91513	50.48041	21.96471	64.34824
190	18.22705	54.0999978	20.73672	60.61424	21.93693	65.98101	20.55537	60.20039
195	20.75432	62.5196402	17.77402	51.84107	22.8929	69.13014	33.54239	98.54781
200	30.8121	92.225563	23.91508	70.02772	8.350189	24.89311	20.37678	59.97357

Performa Jaringan ELM untuk Peramalan Temperatur Maksimum dengan 12 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	0.660861	1.97768232	0.492714	1.439548	0.649338	1.953096	0.526493	1.532444
10	0.58606	1.75727539	0.510465	1.481967	0.551367	1.651907	0.490647	1.428079
15	0.547474	1.64406805	0.425537	1.238084	0.542496	1.621483	0.566816	1.647641
20	0.548525	1.64241756	0.403009	1.172253	0.534904	1.601578	0.669918	1.950006
25	0.510771	1.52773604	0.459143	1.334114	0.49634	1.488109	0.649119	1.891025
30	0.483272	1.44455205	0.469738	1.371982	0.479409	1.439937	0.675978	1.968654
35	0.469904	1.40391601	0.483304	1.407725	0.469112	1.39671	0.678089	1.978679
40	0.469203	1.40095678	0.475881	1.389474	0.432388	1.290732	0.84705	2.471791
45	0.436688	1.31335935	0.572546	1.668806	0.432653	1.29742	0.734503	2.144215
50	0.422228	1.2688007	0.481952	1.408518	0.402553	1.199216	0.89731	2.618514
55	0.391241	1.17092898	0.662897	1.932236	0.389707	1.159811	0.690296	2.010475
60	0.354204	1.05542342	0.603776	1.75878	0.360776	1.081987	1.201597	3.510912
65	0.34579	1.02474186	0.638121	1.857026	0.31554	0.941255	1.204817	3.518111
70	0.34106	1.01496488	0.643081	1.87643	0.302234	0.901106	0.811155	2.355506
75	0.321081	0.95720726	0.757688	2.221161	0.240433	0.716753	1.558637	4.535136
80	0.264941	0.78193588	0.886098	2.588706	0.235376	0.698869	1.290152	3.770352
85	0.257723	0.76862136	0.633332	1.848319	0.186703	0.553747	0.872335	2.548898
90	0.202068	0.59762583	0.730216	2.136152	0.153163	0.454919	1.485197	4.334668
95	0.174062	0.51375792	0.758649	2.215063	0.090379	0.269911	1.984473	5.761403
100	0.134359	0.39775237	0.820691	2.403458	0.049478	0.146287	2.420535	7.065854
105	0.12221	0.3614271	1.201955	3.511443	0.005484	0.01633	3.804681	11.05608
110	0.067121	0.19956282	0.66002	1.923581	1.143398	3.426711	8.19967	23.80564
115	0.031194	0.09229636	1.110047	3.228938	4.899577	14.76172	7.404679	21.68878
120	5.18E-07	1.5536E-06	1.232249	3.589371	7.099307	21.29676	14.66344	42.6281
125	6.127688	18.3531793	6.146995	17.78536	12.98487	38.97651	14.18478	41.68022
130	8.207042	24.6097729	12.03505	35.35461	7.574109	22.74664	10.03145	29.21921
135	13.71715	41.0940145	12.96563	37.64493	7.757821	23.21683	14.8119	43.13197
140	12.43326	36.9676176	10.94721	31.95304	11.10611	33.26403	14.4362	42.19242
145	15.0528	44.810701	16.71205	48.58012	18.79482	56.28287	26.43934	76.74045
150	23.54279	70.7747092	16.15767	46.97994	22.94773	68.91044	30.59883	89.3286
155	19.23064	57.8331134	16.62936	48.10943	20.26435	60.76327	17.47874	50.97947
160	27.922	84.4244532	23.72725	69.04003	24.37842	73.059	36.09126	105.5415
165	26.21719	78.6931581	32.12863	93.91469	29.99692	89.61331	28.63666	83.08227
170	32.16972	96.5379712	28.53568	82.71529	26.21536	79.64659	31.08887	90.27966
175	38.58108	115.004803	50.44525	146.6867	26.14876	78.69835	21.82136	63.58269
180	47.06444	142.377934	33.30433	96.60214	27.95617	83.93097	25.09564	72.67276
185	44.22165	132.955848	31.98836	93.1026	23.21772	69.76712	26.43101	77.12828
190	30.42439	91.8068867	24.87347	72.32637	34.38299	102.3911	66.78428	193.1079
195	51.12075	152.753788	60.00902	175.7953	35.7229	106.4527	47.90997	139.2492
200	54.38782	162.755646	59.6757	173.6401	38.40419	115.2593	45.72118	133.5596

Performa Jaringan ELM untuk Peramalan Temperatur Minimum dengan 6 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	0.769229	12.0576231	0.462298	1.957915	0.705432	11.73974	0.547985	2.30608
10	0.63308	11.4251933	0.573492	2.407182	0.641826	11.45549	0.581482	2.437874
15	0.625158	11.3798511	0.597846	2.505805	0.624341	11.33304	0.683183	2.865065
20	0.626264	11.3495305	0.653512	2.733588	0.631688	11.36152	0.622154	2.60297
25	0.64021	11.3748337	0.594005	2.478071	0.627813	11.30588	0.653996	2.735622
30	0.646365	11.3689373	0.640605	2.674636	0.6506	11.36837	0.730145	3.059273
35	0.658715	11.35223	0.626647	2.614079	0.664282	11.28766	0.851876	3.563442
40	0.661438	11.2828745	0.598384	2.494432	0.656152	11.18854	0.969928	4.071877
45	0.636048	11.1353132	0.64906	2.713561	0.643532	11.15431	1.053168	4.411226
50	0.637458	11.1345587	0.598844	2.496584	0.634695	11.14715	1.145558	4.821661
55	0.646118	11.1046718	0.708066	2.944698	0.631646	10.95046	1.285773	5.373639
60	0.647603	11.1161274	0.766317	3.184762	0.632673	10.8743	1.332481	5.575647
65	0.646718	11.0867294	0.713547	2.963701	0.639595	10.67705	1.979281	8.271237
70	0.642581	11.0550951	0.647028	2.69305	0.631067	10.79978	2.240254	9.336517
75	0.656796	10.7587092	1.561142	6.4831	0.64667	10.61425	2.659478	11.11973
80	0.635027	10.5608025	1.543279	6.400323	0.663407	10.81691	2.801883	11.69748
85	0.667175	10.7689656	2.550352	10.55507	0.743463	11.0224	5.174548	21.58233
90	0.795972	11.251193	1.240332	5.151806	0.919403	11.47926	3.942607	16.57394
95	0.794921	11.0789395	1.722356	7.123202	1.065715	11.98068	5.580089	23.36671
100	1.129815	12.4885326	2.918503	12.13766	1.544582	14.60087	6.247632	26.26617
105	1.350272	13.2061601	1.781955	7.376311	1.587981	13.60377	9.220953	38.48435
110	1.480964	14.2949744	1.773159	7.38924	1.391589	13.60834	14.51227	60.81444
115	2.018851	16.0996358	13.82995	57.37291	1.836012	15.14907	21.95662	92.81053
120	2.144457	17.1883424	6.47022	27.00093	1.612516	14.10478	11.45196	48.04497
125	1.691104	14.513164	6.199872	25.72497	2.17931	15.86633	18.01389	75.58228
130	2.506382	17.5975075	5.531765	23.01257	1.952371	15.34703	14.58548	61.22211
135	3.804169	23.0436954	14.52128	60.18777	2.846331	18.20244	16.91849	70.75862
140	2.833224	20.0457968	18.83804	78.12034	3.439702	20.35043	36.03396	151.21
145	3.724037	23.1927037	10.38191	42.98141	3.532704	22.02917	15.97627	66.79961
150	4.488387	26.5171311	22.39937	92.93137	2.427058	14.93805	70.06098	292.9444
155	5.225792	28.3718511	18.51128	76.86884	3.893214	21.00421	68.71084	287.2322
160	4.529818	26.2979585	3.488969	14.65373	4.131066	24.23522	45.43942	190.2388
165	4.340732	26.5703245	7.458287	31.1401	4.108345	22.03791	37.26212	155.8259
170	6.068577	34.0425739	13.98191	57.91598	5.016377	27.19716	35.91774	149.2396
175	4.520043	25.7022334	12.04256	50.0066	4.44873	24.75037	30.84323	129.534
180	7.204177	40.0663964	14.30936	59.2434	4.912463	25.70006	43.50045	182.5367
185	4.819655	26.8905539	22.02119	91.50855	5.447185	27.07544	69.60044	291.4544
190	6.286849	31.9542732	6.334521	26.46094	3.976676	21.91082	38.32618	160.3393
195	5.40222	29.0645651	23.14451	96.02959	6.634758	34.73167	105.0464	438.3372
200	7.587556	36.4473325	18.60297	77.49688	5.751202	29.69775	62.78877	264.1754

Performa Jaringan ELM untuk Peramalan Temperatur Minimum dengan 12 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	0.473134	1.9599624	0.520852	2.211904	0.469197	1.945734	0.521794	2.217454
10	0.451747	1.87188609	0.460591	1.951929	0.443565	1.841278	0.487034	2.068442
15	0.404257	1.67172945	0.4373	1.846785	0.399045	1.649899	0.47698	2.017876
20	0.379588	1.56877891	0.454035	1.916808	0.378111	1.566156	0.523665	2.213758
25	0.376077	1.55749748	0.397752	1.678696	0.370947	1.536568	0.499479	2.11267
30	0.357188	1.47185075	0.442729	1.864126	0.350657	1.453992	0.545625	2.313912
35	0.345933	1.4314716	0.453651	1.906142	0.332438	1.378905	0.774696	3.28123
40	0.299447	1.23522504	0.457695	1.928466	0.301713	1.249396	0.629155	2.653617
45	0.307038	1.26818707	0.428771	1.792569	0.292723	1.214053	0.712329	3.020685
50	0.294854	1.22021829	0.545765	2.285537	0.268363	1.11151	0.80351	3.3873
55	0.271262	1.11841335	0.465582	1.951507	0.232962	0.962457	1.085225	4.568737
60	0.265008	1.09804804	0.567519	2.359705	0.237049	0.979257	0.904423	3.831966
65	0.247798	1.02124675	0.629208	2.627942	0.219589	0.903388	0.709133	2.990297
70	0.231624	0.95474691	0.695778	2.897604	0.201646	0.833263	1.243206	5.233013
75	0.223062	0.91995061	0.765185	3.177422	0.184591	0.757582	1.339273	5.623683
80	0.20277	0.83395588	0.720454	2.998887	0.170569	0.701844	1.852902	7.741877
85	0.184124	0.758851	0.635818	2.654178	0.155219	0.634176	2.269292	9.584415
90	0.162866	0.67091077	0.646101	2.671935	0.123722	0.505269	2.130134	8.929701
95	0.14871	0.60801449	0.872623	3.632046	0.080179	0.326265	5.054125	21.32835
100	0.125667	0.51429504	1.503093	6.169722	0.046732	0.190368	2.721772	11.39127
105	0.102173	0.41655405	1.108863	4.602144	0.015151	0.061779	7.809952	32.61683
110	0.065968	0.26952825	2.14123	8.843142	0.330864	1.353252	12.64871	52.92734
115	0.02773	0.11309823	6.028455	25.05092	0.418879	1.725414	15.40628	64.87777
120	0.007764	0.03160123	2.311055	9.510984	1.212875	5.00663	15.02693	63.17662
125	0.375671	1.54622636	6.481478	26.80023	2.510288	10.42951	6.648341	28.00592
130	1.584207	6.50274972	7.044764	29.18582	1.690684	6.997554	10.3231	43.30134
135	1.546216	6.39176749	3.692718	15.32575	2.370405	9.798926	11.66212	49.26611
140	1.089118	4.49219917	4.92874	20.57021	3.967003	16.38725	10.13048	42.48418
145	2.541867	10.484102	5.26081	21.83426	4.463004	18.49377	5.706842	23.9953
150	2.927908	12.0636126	12.50294	51.64054	6.009287	24.79285	22.0204	92.6757
155	5.154713	21.2322642	3.874145	16.09593	7.292118	30.01687	7.837625	32.91737
160	4.542965	18.7783512	9.973978	41.42975	5.036639	20.77043	13.1057	54.83662
165	3.249764	13.3599233	4.754505	19.77612	4.845338	20.08739	10.24027	42.83614
170	6.08557	25.135005	4.104805	17.2298	6.675372	27.57613	7.114786	29.59953
175	6.18602	25.5596971	7.992193	33.11672	10.44968	42.87225	13.66103	57.45698
180	4.871903	19.9792249	2.951814	12.36014	10.1295	41.73001	5.824294	24.20914
185	6.86055	28.3091244	11.81061	49.16142	13.39971	54.99695	9.551429	39.96065
190	10.55279	43.2869981	9.456682	39.18906	14.51532	59.68912	21.57706	90.46171
195	9.05978	37.2050761	10.18938	42.73585	14.0575	58.04417	22.9739	96.72942
200	10.20386	41.9469613	9.428446	39.58034	11.0298	45.43486	16.91889	71.18056

Performa Jaringan ELM untuk Peramalan Kelembaban Minimum dengan 6 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	5.006509	9.21172347	4.10367	6.048705	4.969312	9.145887	4.497986	6.607032
10	4.783245	8.89987559	3.860046	5.691884	4.626329	8.488966	4.498777	6.635863
15	4.617812	8.42587534	3.531986	5.263619	4.470985	8.147972	7.024724	10.22937
20	4.394767	7.94265921	3.319513	4.905086	4.113661	7.423788	6.386287	9.261693
25	4.159695	7.55202686	3.404655	5.072279	4.033131	7.225877	5.269819	7.586419
30	4.000961	7.21714095	3.938682	5.834533	3.76754	6.7044	7.528247	10.87744
35	3.767888	6.73668086	3.397576	5.096326	3.649121	6.458156	7.714065	11.13879
40	3.55946	6.3581718	3.696625	5.504417	3.338133	5.941705	8.750485	12.45086
45	3.34898	5.90816838	4.049819	6.04427	3.219346	5.618207	9.997059	14.42337
50	3.005189	5.28078162	4.552047	6.735465	2.917385	4.969985	7.771301	11.25584
55	2.732361	4.71770422	3.913046	5.806817	2.664467	4.708301	15.83267	22.7622
60	2.588177	4.50849973	4.029829	6.012702	2.297774	3.922283	13.00414	18.59466
65	2.507823	4.37632857	4.729067	6.986614	1.986478	3.33042	14.00594	20.06573
70	2.19208	3.75973387	4.524109	6.653298	1.992429	3.313215	20.70774	29.09595
75	2.00222	3.39315223	4.193561	6.159047	1.688858	2.90499	20.06655	28.82029
80	1.86471	3.12043224	3.44482	5.065196	1.515654	2.526707	17.05485	24.40946
85	1.573545	2.64712361	4.136826	6.016756	1.37096	2.313059	39.08353	54.502
90	1.496004	2.48603535	4.27934	6.178567	1.166658	1.94504	28.11181	39.91877
95	1.357146	2.26245577	6.345422	9.056651	0.99478	1.670976	52.62608	73.747
100	1.159593	1.92557434	5.041504	7.281375	0.807664	1.292714	90.85094	129.6485
105	1.101625	1.79543012	7.838384	11.23052	0.563835	0.937263	155.1093	218.5993
110	0.883673	1.41137836	12.08301	17.10089	0.101862	0.160403	195.1493	271.4226
115	0.469906	0.74826945	9.740148	13.92979	0.851841	1.507923	832.7116	1151.159
120	0.313603	0.50166215	9.734594	13.9945	2.327922	4.050832	1255.605	1746.658
125	0.025382	0.04298387	31.15638	44.54632	6.526165	11.54442	362.0821	505.5735
130	4.110965	7.10749173	151.8092	215.4147	10.08323	18.34103	499.6177	691.4845
135	9.4381	16.9508329	77.2962	111.4012	15.32874	25.55239	1185.19	1624.867
140	12.45476	22.1747702	48.99909	70.37577	9.722732	16.68189	521.7813	718.9771
145	17.17409	28.4447821	30.27153	43.50299	13.84542	23.79183	325.3912	473.4481
150	17.38357	30.3709752	33.2762	47.12806	19.15992	32.87806	567.9202	779.091
155	13.05287	22.1443342	54.3323	76.98262	22.66683	39.29944	417.8356	579.1344
160	32.11938	52.4328136	49.57867	72.34023	26.39191	45.08054	438.355	608.3047
165	34.22984	60.1260133	62.18484	89.63952	16.38898	27.59032	289.9983	402.7121
170	32.07713	55.1750746	36.18676	52.2272	29.40673	50.50229	342.4448	479.2488
175	34.27562	57.9247396	55.79929	81.69258	28.80482	50.97208	233.028	331.8072
180	45.41855	74.8390264	63.49518	92.05725	29.63389	50.66769	721.7874	991.6633
185	26.34063	45.8148896	59.50542	86.72792	36.88644	62.77358	162.1332	225.4858
190	53.83095	96.7231062	67.15548	97.28312	32.58718	54.75329	607.3369	838.0536
195	42.85922	77.1017813	80.27936	116.2954	24.63121	41.29696	890.584	1251.913
200	31.21237	54.2315689	55.08235	78.79732	28.59919	49.6146	403.2419	561.9326

Performa Jaringan ELM untuk Peramalan Kelembaban Minimum dengan 12 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	5.104633	9.22982932	4.98375	7.31526	5.195862	9.51853	5.090646	7.467326
10	4.907993	8.89211091	4.652454	6.916873	4.889303	8.832496	4.353147	6.423288
15	4.611696	8.40855365	4.372614	6.443875	4.631505	8.401006	4.569387	6.746175
20	4.438714	7.98469838	4.183614	6.206295	4.251282	7.739948	5.724619	8.371138
25	4.17087	7.50497752	4.840148	7.262518	4.237429	7.624999	5.461032	8.030929
30	3.944227	7.18981834	6.310185	9.122996	4.041817	7.309911	4.537108	6.733784
35	3.691299	6.71230665	6.564346	9.625896	3.731027	6.620607	6.032455	8.742096
40	3.665614	6.67071839	4.831486	6.980338	3.561922	6.294823	6.853452	10.09925
45	3.494934	6.093576	6.949943	10.09602	3.33973	5.883687	7.782387	11.32744
50	2.979122	5.13981277	9.377324	14.03695	3.153803	5.574764	7.945797	11.81008
55	2.992698	5.25136407	9.063829	13.68391	3.042207	5.406124	11.40643	16.61263
60	2.670176	4.52128764	12.04385	17.47925	2.73441	4.894893	7.752505	11.33933
65	2.549239	4.43206123	9.915487	15.22099	2.40846	4.112291	13.638	20.33107
70	2.217082	3.7791041	12.86232	19.29971	2.057578	3.398586	10.15643	14.93775
75	1.81641	3.04027375	18.12234	26.88709	1.944213	3.275102	22.63874	33.53741
80	1.632116	2.66912869	12.25126	18.60185	1.583049	2.54718	11.36946	17.19269
85	1.314706	2.18882759	21.42144	32.01992	1.441297	2.41098	26.16861	38.98024
90	1.057911	1.72408703	22.93702	34.39662	1.155413	1.896395	15.6729	22.65092
95	0.480393	0.76026164	27.99975	42.81624	0.700829	1.142827	38.49925	57.22747
100	0.419707	0.67186026	64.62114	97.77212	0.353489	0.569196	34.54423	51.31616
105	0.090039	0.14523543	45.3652	66.98819	0.046348	0.073763	45.31587	67.34689
110	3.642784	6.18148271	108.1371	158.0931	1.904992	3.20696	93.49505	137.4722
115	13.65035	23.7703412	118.2881	173.2021	6.397001	11.00318	59.71481	88.81645
120	14.02663	24.5098594	135.3185	203.302	8.154224	14.00048	79.18177	118.8581
125	21.11886	34.9745013	207.818	299.8822	13.27935	22.94178	60.86355	90.9356
130	28.78193	48.9910335	100.0804	146.0459	20.63432	35.9361	76.37871	111.4476
135	36.90206	63.9450809	149.4062	222.0711	29.49673	48.76299	63.4965	92.91621
140	37.38443	61.780449	95.11564	146.1947	25.85963	44.00137	175.7987	264.5584
145	33.3386	56.3125058	130.7705	190.6477	22.33212	38.08484	98.8555	144.4297
150	58.62126	100.05946	237.6896	339.5256	47.21097	82.65552	139.22	202.7295
155	60.88602	99.485944	159.3521	235.4639	41.11185	67.22429	110.0073	165.318
160	50.62887	86.0146146	90.29621	134.0684	40.48557	67.06621	129.3271	196.0396
165	78.02597	136.915425	170.1477	248.2874	63.29779	106.6922	533.4084	774.9967
170	75.5969	131.437232	139.8981	212.7196	50.83196	90.71253	167.2105	243.1161
175	99.49745	167.522437	183.0135	277.9804	51.45987	87.24823	186.1398	276.9324
180	97.70931	168.58633	271.9538	397.2345	56.94626	102.0195	101.9247	150.1831
185	78.92397	130.494217	129.4335	193.4246	47.60232	81.44066	163.792	244.7473
190	79.92014	138.751748	186.4871	275.9966	69.90443	118.2846	107.768	156.8878
195	98.87532	166.374196	194.2586	291.4386	64.29764	115.5171	106.6901	155.763
200	89.09582	153.807087	149.7951	218.9986	75.8964	126.3143	141.2592	212.935

Performa Jaringan ELM untuk Peramalan Kelembaban Rata-rata dengan 6 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	2.258584	3.05511832	2.0227	2.665736	2.192405	2.972561	2.137939	2.802679
10	2.078496	2.81955264	2.426481	3.136909	2.049572	2.791197	2.011747	2.632526
15	1.966491	2.6789716	1.793604	2.392567	1.968824	2.683837	2.189709	2.827042
20	1.884315	2.56935144	2.487219	3.220703	1.869277	2.553059	2.436677	3.152109
25	1.798917	2.4520967	2.969455	3.871916	1.792593	2.445429	2.247954	2.95543
30	1.666761	2.27331826	3.370424	4.308751	1.689543	2.30407	4.418493	5.710531
35	1.632247	2.21883793	3.910059	5.08877	1.620165	2.203151	3.052426	3.946055
40	1.475504	2.01465139	4.578583	5.796081	1.467611	2.007923	4.234404	5.465556
45	1.383677	1.88651011	5.05539	6.392558	1.384306	1.890384	5.393814	6.835689
50	1.321216	1.79425542	5.375823	7.024643	1.306305	1.77641	3.719956	4.877504
55	1.193863	1.6251819	4.560562	5.825694	1.193459	1.621846	5.050655	6.513491
60	1.073748	1.46420724	5.347497	6.947226	1.062422	1.4464	4.998845	6.503255
65	1.031123	1.41388346	5.531316	7.041761	1.037292	1.400364	10.39208	12.91562
70	0.961659	1.30750197	10.14637	12.61299	0.961544	1.301201	6.739298	8.615906
75	0.86018	1.16499794	8.968603	11.45896	0.870723	1.188139	7.56839	9.821531
80	0.774929	1.05038475	11.9881	15.16133	0.819837	1.103086	14.56096	18.24982
85	0.704499	0.95472631	12.11023	15.214	0.667887	0.90891	10.72495	13.74363
90	0.568279	0.77060077	11.30446	14.45027	0.551061	0.740743	14.62169	18.67496
95	0.43498	0.58473898	20.21324	25.99918	0.431513	0.57861	27.37695	34.67644
100	0.325349	0.43737636	20.68719	26.10708	0.355283	0.479386	27.5411	35.08763
105	0.211604	0.28181152	31.49483	39.5454	0.189526	0.253261	24.68455	31.39229
110	0.039675	0.05427082	114.7657	142.8677	0.048198	0.065098	44.47881	56.18184
115	1.603433	2.17750963	51.13697	64.92286	1.326504	1.77726	203.6565	257.6758
120	6.772065	9.25638031	113.2972	141.9881	6.098796	8.057873	85.66556	109.3477
125	14.51225	19.3628438	54.19908	67.79247	11.5388	15.5108	106.4502	132.3677
130	18.93159	25.1716417	87.12692	109.065	16.41762	21.85361	51.36794	65.25305
135	32.72775	43.9503021	383.4792	476.4798	16.22376	21.61739	96.45115	119.6736
140	19.93864	26.5797933	318.3081	397.0525	17.81923	23.82	107.3901	134.7324
145	28.75352	38.4202063	117.0622	149.2812	17.50079	23.24947	202.2143	256.3968
150	38.9081	52.6674513	248.3337	315.5687	27.48958	37.68294	77.68702	99.47026
155	33.26685	44.2331261	234.1811	290.2268	20.29757	27.41601	174.0008	220.555
160	53.98155	72.7218563	239.5476	301.1532	15.35959	20.64407	46.67495	58.46847
165	43.63556	57.5999959	84.71842	107.7478	23.08403	30.84309	133.6337	172.0657
170	56.73444	74.6066348	85.55778	109.8422	34.01283	45.53028	78.21801	102.7632
175	29.46045	39.338359	194.9594	244.4773	41.50403	55.38748	147.1285	187.6027
180	58.69278	78.235579	103.5301	132.1743	34.58643	46.72675	60.76214	78.46033
185	70.26605	94.7318163	138.3355	175.6216	37.56018	50.3176	117.3285	146.3387
190	60.65844	81.3295344	172.0498	220.4348	36.88315	49.15784	78.55755	99.97784
195	59.16117	79.6245619	95.45947	122.1067	30.27461	41.00459	68.82517	88.5518
200	71.71349	97.6731351	106.931	137.653	53.8035	71.85328	139.1169	176.2017

Performa Jaringan ELM untuk Peramalan Kelembaban Rata-rata dengan 12 Neuron Input

Hidden Neuron	Fungsi Aktivasi Sigmoid Bipolar				Fungsi Aktivasi Sigmoid Biner			
	Training		Testing		Training		Testing	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
5	2.384705	3.24077178	2.123129	2.755851	2.322114	3.14429	2.392616	3.104461
10	2.167731	2.91914773	2.264495	2.987326	2.166366	2.94263	2.271308	3.003633
15	2.066957	2.7935941	2.390269	3.088931	2.069853	2.806583	3.132529	4.104552
20	1.970199	2.68753244	3.367434	4.566645	1.86549	2.534366	2.577749	3.327883
25	1.819131	2.48097002	3.475202	4.632672	1.807768	2.466254	2.823641	3.733069
30	1.772499	2.41350158	3.088479	4.079801	1.73546	2.368618	4.166089	5.54432
35	1.674757	2.27921296	3.428885	4.59072	1.628855	2.206881	4.061704	5.224809
40	1.586449	2.16094473	4.150236	5.558659	1.540211	2.100625	3.556398	4.713552
45	1.49024	2.02490874	4.384812	5.85384	1.459202	1.970451	6.077377	8.004063
50	1.37473	1.85547757	4.73099	6.230561	1.224574	1.657619	4.711223	6.202304
55	1.187832	1.61654698	5.469473	7.218034	1.230282	1.673771	6.40947	8.408754
60	1.167123	1.58164603	6.463536	8.488937	1.112084	1.510397	6.570767	8.737486
65	0.982035	1.3474024	5.01739	6.559681	1.070872	1.453709	6.164364	8.183219
70	0.998248	1.35017066	7.772189	10.22155	0.965587	1.297312	8.324997	11.02513
75	0.838124	1.1213908	6.349911	8.307544	0.852093	1.15285	7.629654	9.909339
80	0.731225	0.9913545	7.76975	10.46917	0.655539	0.880917	9.172596	12.1157
85	0.56169	0.76236163	8.652848	11.42875	0.626965	0.843843	11.12993	14.37996
90	0.376044	0.5087313	12.54211	16.20898	0.468586	0.630896	21.91078	28.53591
95	0.381756	0.50863175	13.94002	18.71167	0.376092	0.505101	19.95348	26.05987
100	0.149166	0.20248799	15.13722	19.5539	0.16466	0.221414	18.39367	24.01678
105	0.021859	0.02930483	21.48313	28.45822	0.040459	0.054197	18.97276	24.58845
110	4.027836	5.37173495	26.04757	33.70163	3.386482	4.503415	73.60659	96.96265
115	13.04611	17.2914485	32.79533	42.56295	8.552717	11.39633	26.43049	34.60559
120	30.75307	40.960638	95.12684	123.299	16.64379	22.34112	32.8521	42.50371
125	29.31247	39.196777	90.14121	118.1386	19.15346	25.325	62.36338	80.51088
130	34.98683	46.4600258	87.30573	115.045	22.05824	29.7408	62.45506	83.03202
135	39.80178	53.2670715	477.7154	636.6058	25.24978	33.80558	48.40995	63.6587
140	43.69377	58.6994879	1237.604	1643.359	40.17374	53.83942	80.13798	107.4035
145	71.04462	94.4046433	129.4379	169.7486	34.7979	46.15984	70.1403	91.84017
150	74.38555	99.3449335	121.6248	160.972	45.48125	60.08071	93.14216	121.4343
155	61.37906	82.8912707	117.8754	153.6208	33.59582	45.22448	58.68431	78.90679
160	81.21368	108.139297	186.2329	239.3051	78.88226	105.1934	129.1675	168.8327
165	107.0115	142.008358	266.7682	350.5647	64.90414	85.38302	140.6952	182.7228
170	116.1098	157.5314	138.7551	181.5143	58.44015	77.62774	135.1386	177.9631
175	101.9345	137.096099	211.0878	280.3625	59.61382	79.53277	99.40192	128.7664
180	128.3476	172.420822	269.6175	352.1937	58.01791	78.43722	270.4457	361.2718
185	116.0712	157.621527	238.6275	311.4357	82.34369	109.4535	129.0007	167.5211
190	125.7878	167.542606	282.5158	372.0778	63.45402	84.23646	183.2946	237.7431
195	135.2188	178.784838	250.2999	328.4863	98.23952	130.8502	264.8092	353.5179
200	141.1493	187.900915	320.9437	423.6311	91.68803	123.1169	671.9026	870.6577

BIODATA PENULIS



Penulis bernama Abdul Mahatir Najar, lahir di Baucau, 29 April 1992, merupakan anak kedua dari enam bersaudara. Penulis menempuh pendidikan formal di SDN Pengawu Palu, SMPN 3 Palu dan MAN 2 Model Palu. Setelah lulus dari Madrasah Aliyah penulis melanjutkan studi S1 Jurusan Matematika di Universitas Tadulako pada tahun 2010 - 2014. Sempat bekerja di kantor Bawaslu Provinsi Sulawesi tengah, Penulis kemudian melanjutkan studi S2 Jurusan Matematika di Institut Teknologi Sepuluh Nopember pada tahun 2016 dengan Tesis pada bidang Ilmu Komputer.

Penulis dapat dihubungi melalui e-mail : *abdulmahatir@gmail.com*.