

**PREDIKSI CURAH HUJAN KECAMATAN DI JAWA TIMUR
MENGUNAKAN ALGORITMA *BACKPROPAGATION NEURAL NETWORK*
BERDASARKAN FAKTOR PENENTU CURAH HUJAN**

SKRIPSI

Oleh :
MAULIDA DWI ARIANI
NIM. 18650059



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2022**

**PREDIKSI CURAH HUJAN KECAMATAN DI JAWA TIMUR
MENGUNAKAN ALGORITMA *BACKPROPAGATION NEURAL
NETWORK* BERDASARKAN FAKTOR PENENTU CURAH HUJAN**

SKRIPSI

Oleh :
MAULIDA DWI ARIANI
NIM. 18650059

Diajukan Kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri (UIN) Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2022**

HALAMAN PERSETUJUAN

**PREDIKSI CURAH HUJAN KECAMATAN DI JAWA TIMUR
MENGUNAKAN ALGORITMA *BACKPROPAGATION NEURAL*
NETWORK BERDASARKAN FAKTOR PENENTU CURAH HUJAN**

SKRIPSI

Oleh :
MAULIDA DWI ARIANI
NIM. 18650059

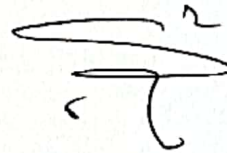
Telah Diperiksa dan Disetujui untuk Diuji
Tanggal: 1 Desember 2022

Pembimbing I



Okta Oomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013


Pembimbing II



Syahiduz Zaman, M.Kom
NIP. 19700502 200501 1 005

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT.IPM
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PREDIKSI CURAH HUJAN KECAMATAN DI JAWA TIMUR MENGUNAKAN ALGORITMA *BACKPROPAGATION NEURAL NETWORK* BERDASARKAN FAKTOR PENENTU CURAH HUJAN

SKRIPSI

Oleh :
MAULIDA DWI ARIANI
NIM. 18650059

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal : 9 Desember 2022


Susunan Dewan Penguji

Ketua Penguji : Dr. Ririen Kusumawati, S.Si., M.Kom
NIP. 19720309 200501 2 002
Anggota Penguji I : A'la Syauqi, M.Kom
NIP. 19771201 200801 1 007
Anggota Penguji II : Okta Oomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013
Anggota Penguji III : Syahiduz Zaman, M.Kom
NIP. 19700502 200501 1 005



Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan M.MT., IPM
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Maulida Dwi Ariani
NIM : 18650059
Jurusan : Teknik Informatika
Fakultas : Sains dan Teknologi
Judul Skripsi : Prediksi Curah Hujan Kecamatan di Jawa Timur
Menggunakan Algoritma *Backpropagation Neural Network* Berdasarkan Faktor Penentu Curah Hujan

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan Skripsi ini hasil jiplakan maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 30 November 2022
Yang membuat pernyataan,



Maulida Dwi Ariani
NIM. 18650059

HALAMAN MOTTO

“Apapun yang kamu lakukan, Jalani, Nikmati, Syukuri...”

HALAMAN PERSEMBAHAN

Skripsi ini saya persembahkan untuk
Ayah Saya Abdul Ghoni, Ibu Saya Anisah, Saudara, Keluarga,
Seluruh Dosen, Sahabat,
Teman-teman seperjuangan dan
Diri saya sendiri

Terima kasih..

KATA PENGANTAR

Assalamualaikum Wr. Wb.

Alhamdulillah puji syukur penulis panjatkan kehadirat Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, memudahkan dan meridhoi peneliti dalam menyelesaikan skripsi ini. Skripsi ini ditulis untuk memenuhi syarat kelulusan mahasiswa Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang. Keberhasilan penulisan skripsi ini tidak terlepas dari dorongan dan bimbingan dari semua pihak. Oleh karena itu, pada kesempatan ini, penulis ingin menyampaikan terima kasih yang tulus kepada:

1. Prof. Dr. H.M. Zainuddin, MA selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Sri Hariani, M.Si selalu dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Fachrul Kurniawan, M.MT., IPM selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang
4. Okta Qomaruddin Aziz, M.Kom selaku dosen pembimbing I yang telah bersedia meluangkan waktunya dalam membimbing dan memberikan dorongan dan arahan kepada peneliti sehingga dapat menyelesaikan skripsi ini.
5. Syahiduz Zaman, M.Kom selaku dosen pembimbing II yang juga bersedia meluangkan waktunya dalam memberikan arahan dan membimbing kepada peneliti sehingga dapat menyelesaikan skripsi ini.
6. Ayah saya Abdul Ghoni dan ibu saya Anisah yang telah memberikan banyak dukungan baik secara finansial, moral dan spiritual, serta Kakak saya Iswanto yang selalu memberikan dukungan dalam bentuk bullying sehingga membuat penulis menyelesaikan skripsi dengan lebih semangat.
7. Keluarga besar saya yang selalu mendukung, memberikan motivasi, memberikan semangat dan doa sehingga penulis bisa mengerjakan skripsi dengan lancar dan diberikan kemudahan kelancaran dalam menyelesaikan skripsi ini.

8. Seluruh dosen dan staff Program Studi Teknik Informatika yang telah memberikan ilmu dan pengalaman yang berharga.
9. Sahabat-sahabat saya Asfilia Nova, Nurlaili Khairani, Ulyana Alfiani, Tasya Adha dan Aulia Ananda yang selalu membantu dan memberikan informasi terkait pengerjaan skripsi ini.
10. Ustadz/ah saya di Pesma Firdaus yang senantiasa mendoakan dan memberikan semangat serta teman-teman Pesma yang selalu memberikan dorongan motivasi selama pengerjaan skripsi.
11. Teman-teman UFO yang sama-sama mengejar gelar S.Kom di Universitas yang sama.
12. Kepada A terimakasih telah meluangkan waktu menemani, membantu dan memberikan dukungan dalam pengerjaan skripsi ini.
13. Diri saya sendiri yang mampu terus maju dan semangat walaupun terdapat beberapa kendala dan halangan ditengah-tengah perjalanan pengerjaan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Maka dari itu penulis akan menerima saran dan kritik yang membangun. Terlepas dari itu semua, penulis berharap agar skripsi ini dapat memberikan manfaat bagi para pembaca.

Wassalamualaikum Wr. Wb.

Malang, 30 November 2022

Penulis

DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
HALAMAN MOTTO	vi
HALAMAN PERSEMBAHAN	viii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
ABSTRAK	xiv
ABSTRACT	xv
مستخلص البحث	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan	6
1.4 Batasan Masalah.....	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	8
2.1 Penelitian Terdahulu	8
2.2 Prediksi.....	10
2.3 Curah Hujan	11
2.4 <i>Artificial Neural Network</i> (ANN)	14
2.4.1 Arsitektur ANN.....	15
2.4.2 Algoritma Backpropagation Neural Network (BPNN).....	19
2.4.3 Fungsi Aktivasi	24
2.4.4 Normalisasi Data.....	25
2.4.5 Denormalisasi Data	25
2.4.6 Nilai MSE	26
2.4.7 Nilai MAPE	27
BAB III DESAIN DAN IMPLEMENTASI	28
3.1 Prosedur Penelitian.....	28
3.2 Data yang digunakan.....	29
3.3 Desain Sistem.....	31
3.4 Preprocessing.....	35
3.4.1 Normalisasi	35
3.4.2 Pembagian Data	36
3.4.3 Proses ANN <i>Backpropagation</i>	36
3.4.5 Denormalisasi	38
3.5 Proses Training.....	39

BAB IV UJI COBA DAN PEMBAHASAN	41
4.1 Skenario Model	41
4.2 Hasil Pengujian Model	42
4.2.1 Pengujian Model Pertama	42
4.2.2 Pengujian Model Kedua	44
4.3 Pembahasan Pengujian Model	46
BAB V PENUTUP	53
5.1 Kesimpulan	53
5.2 Saran	53
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 2.1 Interaksi Sinyal dari n Neuron dan Analogi dengan Penjumlahan Sinyal dalam Neuron Buatan terdiri dari Perceptron Lapisan Tunggal	15
Gambar 2.2 Komponen Matematis Neuron	16
Gambar 2.3 Arsitektur Neural Network.....	17
Gambar 2.4 Single Layer Network	18
Gambar 2.5 Multilayer Network	19
Gambar 2.6 Fungsi Aktivasi	24
Gambar 3.1 Diagram Blok Prosedur Penelitian.....	28
Gambar 3.2 Diagram Blok ANN Backpropagation	32
Gambar 3.3 Flowchart Tahapan Prediksi Menggunakan ANN Backpropagation.....	33
Gambar 3.4 Contoh Arsitektur ANN dengan 8 <i>Input</i> , 1 <i>Hidden Layer</i> dan 1 <i>Output</i>	34
Gambar 3.5 Nilai Data Setelah Proses Normalisasi (a) Data Asli (b) Data Hasil Normalisasi	36
Gambar 3.6 Nilai Data Setelah Proses Denormalisasi (a) Data Normalisasi (b) Data Hasil Denormalisasi	39
Gambar 3.7 Grafik MSE Curah Hujan Kecamatan Berdasarkan 8 Faktor Penentu Curah Hujan	39
Gambar 3.8 Grafik MSE Curah Hujan Kabupaten Berdasarkan Suhu Dan Kelembaban	40
Gambar 4.1 Grafik Perbandingan Data Aktual Dan Prediksi	51

DAFTAR TABEL

Tabel 2.1 Klasifikasi MAPE	27
Tabel 3.1 Contoh Data Curah Hujan dan Faktor Penentu Curah Hujan Kecamatan di Jawa Timur Periode 2017	30
Tabel 3.2 Contoh Data Curah Hujan Berdasarkan Suhu Dan Kelembapan Pada Kabupaten/Kota di Jawa Timur	31
Tabel 4.1 Hasil Pengujian Model Pertama ANN	42
Tabel 4.2 Hasil Pengujian Model Kedua ANN	45
Tabel 4.3 Hasil Pengujian Model AC dengan Standar Deviasi	47
Tabel 4.4 Hasil Pengujian Model AR dengan Standar Deviasi	48
Tabel 4.5 Hasil Pengujian Model BB dengan Standar Deviasi	48
Tabel 4.6 Denormalisasi Model AR	50

ABSTRAK

Ariani, Maulida Dwi, 2022. **Implementasi *Backpropagation Neural Network* untuk Prediksi Curah Hujan Kecamatan di Jawa Timur berdasarkan Faktor Penentu Curah Hujan**. Skripsi. Program Studi Teknik Informatika, Fakultas Sains dan Teknologi. Universitas Maulana Malik Ibrahim Malang. Pembimbing: (I) Okta Qomaruddin Aziz, M.Kom (II) Syahiduz Zaman, M.Kom

Kata Kunci: *Neural Network Backpropagation, Curah Hujan, Prediksi*.

Kondisi iklim yang tidak menentu saat ini menyebabkan curah hujan tinggi atau rendah, sehingga mengalami kesulitan dalam memprediksi curah hujan. Namun, dengan bantuan data mining menggunakan curah hujan pada masa mendatang dapat diprediksi berdasarkan faktor yang mempengaruhi curah hujan, seperti: kelembaban udara, tekanan udara, suhu dan kecepatan angin. Salah satu sistem pemrosesan yang dapat digunakan dalam melakukan prediksi adalah jaringan saraf tiruan. Metode yang sering digunakan pada prediksi menggunakan sistem jaringan saraf tiruan adalah backpropagation. Backpropagation memiliki pola yang cocok digunakan untuk membuat prediksi masa depan. Proses perhitungan yang mudah dan sederhana namun juga berkinerja baik, bahkan dengan data yang kompleks. Hasil pengujian model prediksi curah hujan kecamatan berdasarkan 8 faktor penentu curah hujan memiliki nilai MAPE yang relatif lebih kecil. Sedangkan pada prediksi curah hujan kabupaten berdasarkan suhu dan kelembaban memiliki rata-rata nilai MAPE yang lebih besar. Dari model yang telah dibangun ditemukan model jaringan saraf tiruan terbaik, yaitu model AR dengan arsitektur 8-4-1 dan learning rate sebesar 0,18 rata-rata MAPE sebesar 14,52% dan Standar Deviasi sebesar 2,10%.

ABSTRACT

Ariani, Maulida Dwi, 2022. **Implementation Of Backpropagation Neural Network For Rainfall Prediction In East Java Based On Rainfall Determinants**. Thesis. Department of Information Engineering, Faculty of Science and Technology. University Of Maulana Malik Ibrahim Malang. Supervisor: (I) Okta Qomaruddin Aziz, M.Kom (II) Syahiduz Zaman, M.Kom

Keywords: *Neural Network Backpropagation, Rainfall, Prediction.*

Today, erratic climate conditions cause high or low rainfall, thus experiencing difficulties in predicting rainfall. But with the help of data-mining uses rainfall, it can be used to predict the future based on factors affecting rain, such as humidity, air pressure, temperature, and wind speed. One of the processing systems that can be used for prediction is Artificial Neural Network. A method often used in predictions using Artificial Neural Network systems is backpropagation. Backpropagation has a suitable pattern used to make future predictions. The calculating process is simple and easy, but it works well even with complex data. The results of testing the district rainfall prediction model based on 8 factors determining rainfall have a relatively smaller MAPE value. In the meantime, predictions of district precipitation based on temperature and humidity have a higher average MAPE value. From the model built, the best artificial neural network model was acquired, namely the AR model with an 8-4-1 architecture and a learning rate of 0.18, an average MAPE of 14.52%, and a Standard Deviation of 2.10%.

مستخلص البحث

أرياني ، موليدا دوي . ٢٠٢٢ . التنبؤ سكب المطر في ناحية جاوة الشرقية باستخدام الشبكة العصبية الاصطناعية للتكاثر حسب العامل المحدد بسكب المطر اخلفي . فرضية. قسم هندسة المعلوماتية ، كلية العلوم والتكنولوجيا ، جامعة الدولة الإسلامية مولانا مالك إبراهيم مالانج. المشرفون: (١) أوكتا قمر الدين عزيز الماجستير (٢) سياحدوز زمان ماجستر

الكلمات المفتاحية: الشبكة العصبية الاصطناعية ، سكب المطر، التنبؤات.

يسبب المناخ غير مؤكد إلى سكب المطر العالية أو الرذيل ويجعله أن يصعب سكب المطر. ولكن، بمساعدة Data Mining باستخدام سكب المطر فيستطيع أن يتنبأ حسب العامل الأثر بسكب المطر في المستقبل مثلاً: رطوبة الهواء وقوة الهواء ودرجة الحرارة وسريعة الريح. في هذا البحث أن Neural Network احدى أنظمة المعالجة المستخدمة في عمل التنبؤ. أغلب المنهج للتنبؤ باستخدام نظام Neural Network هو Backpropagation. يحتوي Backpropagation على نمط مناسب في التنبؤ المستقبل. مع ذلك، عملية حسابه سهل وبسيط ويعمل بجيد مع البيانات المجمعة. نتائج اختبار سكب المطر على مستوى الفرعية المستند إلى ثمانية عوامل المحدد لها قيمة MAPE أصغر نسبياً، بخلاف سكب المطر على مستوى المديرية المستند إلى درجة الحرارة والرطوبة لها قيمة متوسط MAPE أكبر نسبياً. من المثال الذي تم بناؤه، وجد أن أفضل المثال للشبكة العصبية الاصطناعية (Neural Network) هو مثال AR بهندسة ٨-٤-١ ومستوى التعلم 0,18 ومعدل MAPE هو 14,52% والانحراف المعياري هو 2,10%

BAB I

PENDAHULUAN

1.1 Latar Belakang

Peristiwa cuaca ekstrem di seluruh dunia pada tahun 2021 mencapai rekor. Gelombang tinggi yang disebabkan oleh pemanasan planet membuat daerah pesisir lebih rentan terhadap bencana. Cuaca ekstrem juga terjadi, termasuk kekeringan yang mengakibatkan kebakaran hutan dan hujan intensitas tinggi yang menghasilkan tanah longsor dan banjir. Cuaca ekstrem dipengaruhi oleh cuaca dan perubahan iklim yang disebabkan oleh manusia, seperti pemanasan global yang disebabkan oleh emisi gas rumah kaca. Hal ini menantang bagi para ilmuwan untuk meramalkan perubahan cuaca di masa depan karena bencana yang terjadi lebih sering dan dengan intensitas yang lebih besar (Duarte, 2021).

Cuaca merupakan faktor penting dalam kehidupan manusia, terutama di bidang pertanian, penerbangan, kelistrikan, penampungan air, pariwisata dan sektor lainnya. Peningkatan curah hujan yang terjadi pada akhir-akhir ini mengingatkan manusia pada firman Allah SWT dalam surah Al-A'raf ayat 57 yang berbunyi:

وَهُوَ الَّذِي يُرْسِلُ الرِّيحَ بُشْرًا بَيْنَ يَدَيْ رَحْمَتِهِ ۗ حَتَّىٰ إِذَا أَقْلَّتْ سَحَابًا ثِقَالًا سُقْنَهُ لِبَلَدٍ مَّيِّتٍ فَأَنْزَلْنَا بِهِ الْمَاءَ فَأَخْرَجْنَا بِهِ ۖ مِنْ كُلِّ الثَّمَرَاتِ ۗ كَذَٰلِكَ نُخْرِجُ الْمَوْتَىٰ لَعَلَّكُمْ تَذَكَّرُونَ

“Dialah yang mendatangkan angin sebagai kabar gembira yang mendahului kedatangan rahmat-Nya (hujan) sehingga apabila (angin itu) telah memikul awan yang berat, Kami halau ia ke suatu negeri yang mati (tandus), lalu Kami turunkan hujan di daerah itu. Kemudian Kami tumbuhkan dengan hujan itu berbagai macam buah-buahan. Seperti itulah Kami membangkitkan orang-orang mati agar kamu selalu ingat.” (Q.S. Al-A'raf 57)

Ayat 57 menjelaskan tentang salah satu nikmat yang diberikan oleh Allah kepada manusia yaitu dengan mengirimkan awan lebat ke tempat yang kering

karena telah menghancurkan tanaman dan sumber air, menyebabkan penduduk setempat menderita kehausan dan kelaparan. Kemudian, dari awan-awan ini, datanglah hujan lebat, yang memulihkan kesuburan wilayah itu dengan persediaan air yang penuh dan banyak tanaman (Mustakim, 2011).

Sebelum hujan turun, Allah mengirimkan angin yang mengarak partikel-partikel awan yang mengandung air sebelum hujan. Sebelum Hujan mulai turun, awan mulai menggumpal dan tumpang tindih satu sama lain. Ketika partikel-partikel awan tersebut tertiup angin, awan tersebut terlihat ringan. Namun, setelah menyatu menjadi gumpalan, awan tersebut menjadi berat dan gerakannya menjadi lambat. Hal ini menunjukkan bahwa Allah akan membawa hujan ke daerah tersebut. (Shihab, 2013).

Kondisi iklim yang tidak menentu saat ini menyebabkan curah hujan menuju arah (trend) tinggi atau rendah, sehingga mengalami kesulitan dalam memprediksi curah hujan (Muflih, Sunardi, & Yudhana, 2019). Tetapi, dengan bantuan teknik *data mining* yang menggunakan data curah hujan masa lalu, curah hujan di masa depan dapat diprediksi yaitu dengan menjadikannya sebagai *input*. Data mining dapat mengolah data yang sangat besar secara cepat dan akurat, sehingga dapat membantu dalam memprediksi perubahan cuaca di masa depan (Nanda, Pudjiantoro, & Sabrina, 2022). Curah hujan merupakan salah satu bentuk fenomena lingkungan yang memegang peranan paling penting dalam kehidupan manusia terutama pada sektor pertanian dalam memproduksi tanaman. Banyak sedikitnya curah hujan akan berpengaruh dalam menentukan hasil tanaman (Anwar et al., 2015).

Penelitian sebelumnya Aprianto & Puspitasari (2020) memprediksi curah hujan dengan berdasarkan periode waktu bulan. Periode waktu tersebut memiliki kelemahan, yaitu beberapa stasiun pemantau BMKG di beberapa daerah pada bulan tertentu tidak memiliki pencatatan, atau bahkan hilang karena alat perekam tidak dapat merekam secara normal. Menurut Sofian dan Y Apriani (2017) jika menggunakan periode waktu, data yang hilang pada waktu tertentu tidak dapat menghitung. Oleh karena itu, fokus penelitian ini adalah untuk memprediksi curah hujan di suatu daerah khususnya wilayah kecamatan di Jawa Timur. Hal ini akan memberikan gambaran tentang kondisi iklim yang akan terjadi sehingga dapat diambil langkah-langkah antisipatif terhadap kemungkinan-kemungkinan yang tidak diharapkan.

Curah hujan adalah jumlah air hujan yang jatuh ke permukaan bumi dalam periode tertentu di wilayah tertentu. Curah hujan dapat diukur dalam periode harian, bulanan, atau tahunan. Curah hujan di suatu wilayah bervariasi berdasarkan beberapa faktor. Ada banyak faktor yang mempengaruhi curah hujan, diantaranya: kelembaban udara, tekanan udara, suhu, dan kecepatan angin (Wilson, 1993).

Berdasarkan data historis, besarnya data curah yang akan terjadi di masa depan tidak dapat ditentukan dengan pasti tetapi dapat diprediksi berdasarkan data curah hujan masa lalu. Selain itu, prakiraan curah hujan secara rinci pada tiap daerah masih kurang (Ardana, Sudika, Astariani, & Sumarda, 2019). Pengetahuan yang akurat tentang curah hujan sangat diperlukan untuk suatu wilayah yang sangat penting di berbagai sektor dalam persiapan dan pengendalian pasokan air

serta untuk pemeliharaan waduk dan pengendalian banjir (Narvekar, Fargose, & Mukhopadhyay, 2017).

Pentingnya prakiraan curah hujan, selain dapat mempengaruhi debit sungai, juga dapat digunakan untuk meminimalkan dampak bencana curah hujan seperti tanah longsor, karena hujan lebat di daerah pegunungan dapat memicu bencana sehingga berdampak pada infrastruktur publik, jaringan pembuangan limbah dan aktivitas manusia lainnya. Proses prediksi curah hujan membutuhkan keakuratan karena dapat digunakan untuk berbagai kebutuhan, sehingga dapat diketahui berapa besar curah hujan yang akan datang (Sunardi, Anton Yudhana, 2020).

Backpropagation adalah metode pembelajaran terawasi yang populer dan memiliki keunggulan dalam kemampuan pembelajarannya. Ketika merencanakan masa depan, data historis digunakan untuk mengidentifikasi tren jangka pendek, jangka menengah, atau jangka panjang. Selain itu, *backpropagation* cocok digunakan untuk membuat prediksi masa depan karena memiliki proses perhitungan yang mudah dan sederhana namun juga memiliki kinerja yang baik, bahkan dengan data yang kompleks (Siregar, Sandi, 2017). *Artificial Neural Network* (ANN) atau Jaringan Saraf Tiruan merupakan salah satu sistem pemrosesan yang dapat digunakan untuk melakukan prediksi. ANN didesain dengan menirukan cara kerja otak manusia, dan memiliki kemampuan untuk mengenali kejadian berdasarkan data masa lampau yang telah dipelajari, sehingga mampu memberikan keputusan terhadap data yang belum pernah ada sebelumnya. (Priyo, Helmie, Indra, Nurdin, & K, 2016).

Salah satu metode yang dapat digunakan untuk menentukan besar kecilnya kesalahan hasil prediksi yaitu MAPE. Dengan menggunakan *Mean Absolute Percent Error (MAPE)* dapat mendapatkan hasil prediksi dengan meminimalkan kesalahan dan menghindari ketidakpastian dalam data prediksi. *Mean Absolute Percent Error (MAPE)* menunjukkan tingkat kesalahan absolut dalam prediksi dengan nilai aktual (Nabillah & Ranggadara, 2020).

Berdasarkan pada masalah tersebut maka diusulkan sebuah penelitian **“Prediksi Curah Hujan Kecamatan Di Jawa Timur Menggunakan Algoritma *Backpropagation Neural Network* Berdasarkan Faktor Penentu Curah Hujan”**. Data yang digunakan dalam penelitian ini merupakan data-data yang berkaitan dengan kondisi cuaca pada kecamatan, seperti suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut, ketersediaan air, dan curah hujan selama periode 2017-2021. Dengan mengumpulkan dan menganalisis data-data tersebut, diharapkan sistem yang diusulkan dapat memberikan keluaran berupa prediksi dini curah hujan yang dapat membantu dalam mengatasi permasalahan bencana yang akan datang.

1.2 Rumusan Masalah

Berdasarkan pada latar belakang yang telah dijelaskan, rumusan masalah yang diambil adalah berapa nilai MAPE algoritma *Backpropagation* dalam memprediksi curah hujan Kecamatan di Jawa Timur berdasarkan Faktor Penentu Curah Hujan?

1.3 Tujuan

Berdasarkan masalah yang telah dijelaskan, maka tujuan dari penelitian adalah untuk menganalisis nilai MAPE algoritma *Backpropagation* dalam memprediksi curah hujan Kecamatan di Jawa Timur berdasarkan Faktor Penentu Curah Hujan.

1.4 Batasan Masalah

Batasan masalah yang diterapkan dalam penelitian ini adalah :

1. Data yang digunakan adalah data curah hujan di Kecamatan yang berada di Jawa Timur yang meliputi Kabupaten Malang, Kota Malang, Kota Batu, Kabupaten Pasuruan, Kota Pasuruan, Kabupaten Madiun, Kota Madiun, Kabupaten Tulungagung, dan Kabupaten Blitar yang didapatkan dari *scrapping* data secara manual.
2. Data yang diambil berupa data suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut, ketersediaan air dan curah hujan kecamatan di Jawa Timur periode 2017-2021.

1.5 Manfaat Penelitian

Berikut beberapa manfaat yang diperoleh dari penelitian prediksi curah hujan kecamatan di Jawa Timur, baik bagi peneliti maupun pembaca:

1. Memprediksi curah hujan kecamatan di Jawa Timur melalui perhitungan Jaringan Saraf Tiruan dengan menggunakan metode *Backpropagation* dapat digunakan sebagai acuan dalam pengambilan keputusan terkait kebijakan dan

tindakan pencegahan bencana yang disebabkan oleh curah hujan yang tidak terprediksi.

2. Dapat membantu masyarakat dalam mengambil tindakan preventif terhadap potensi bencana yang mungkin terjadi.
3. Menambah ilmu dan pengalaman bidang Teknik Informatika, serta sebagai salah satu syarat untuk meraih gelar sarjana strata satu di Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
4. Dapat menjadi bahan referensi bagi penelitian selanjutnya yang berkaitan dengan prediksi curah hujan di daerah lain.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terdahulu

Penelitian yang dilakukan Handayani & Adri (2015) memiliki tujuan untuk mengaplikasikan jaringan saraf tiruan *backpropagation* dalam memprediksi curah hujan di kota pekanbaru dengan menggunakan data tahun 2013 yang terdiri dari 344 data. Fungsi aktivasi yang didapatkan sebesar 99,99% dan tansig 99,97%. Sedangkan nilai akurasi peramalan sebesar 96% dengan data yang digunakan adalah bulan januari 2013 terdiri 29 data. Tingkat keakuratan yang tinggi ini menunjukkan bahwa sistem tersebut dapat digunakan untuk memprediksi cuaca di hari berikutnya dengan tingkat keakuratan yang tinggi.

Prediksi curah hujan dilakukan oleh Sharma & Nijhawan (2015) di wilayah Delhi, India. Data yang diambil berasal dari situs meteorologi pada periode mei hingga September. Dengan melakukan perhitungan pada data *training*, data *testing* dan mendeteksi jaringan neuron yang tersembunyi dari tiga algoritma yang berbeda. Terdapat 3 algoritma yang diuji pada arsitektur *multilayer*, diantaranya algoritma *backpropagation*, *cascaded backpropagation* dan *layer recurrent network*. Hasil yang didapat adalah arsitektur multilayer yang diuji dengan algoritma *backpropagation* menunjukkan konsistensi dan akurasi yang baik dibandingkan algoritma lainnya. Nilai *Error Minimum* (MSE) yang dihasilkan adalah 6,58 dengan menunjukkan kinerja terbaik pada 15 *epoch*.

Penelitian tentang prediksi curah hujan telah dilakukan oleh para peneliti sebelumnya. Peneliti Lesnussa, Mustamu, Kondo Lembang, & Talakua (2018) telah

memprediksi curah hujan dengan menggunakan *Backpropagation Artificial Neural Network* dengan bantuan software MATLAB dan menghasilkan tingkat akurasi prediksi curah hujan sebesar 80%, dengan menggunakan alpha 0.7, *epoch* 10000 dan nilai MSE sebesar 0.022.

Menurut Sharaff & Roy (2018) telah melakukan penelitian dalam memprediksi suhu menggunakan model regresi linier, model pohon regresi dan *backpropagation neural network*. Dari tiga model tersebut disimpulkan bahwa *Artificial Neural Network* dengan *backpropagation* melakukan kinerja lebih baik dibandingkan model yang lain. Kemampuan dalam menemukan hubungan non-linier antara atribut dan output dapat bekerja dengan baik. Selain itu, cuaca yang berubah-ubah menyebabkan sulit untuk diprediksi sehingga tidak dapat memiliki hubungan linier dan tidak dapat diklasifikasikan berdasarkan rentang atribut nilai. Nilai MSE yang dihasilkan adalah 3,68 untuk model regresi linier, 4,01 untuk model pohon regresi dan 3,46 untuk model jaringan saraf *backpropagation*. Oleh karena itu, model jaringan saraf *backpropagation* lebih cocok digunakan dalam prediksi cuaca.

Menurut Sunardi, Anton Yudhana (2020) menyatakan bahwa pengujian pada sistem dalam memprediksi curah hujan dengan menggunakan *black box testing* yang dibangun menghasilkan akurasi pelatihan sebesar 93,92 dengan validasi sebesar 73,04%. Hal ini menunjukkan bahwa sistem dapat berfungsi dengan baik dan berjalan sesuai rencana. Arsitektur JST terbaik ditemukan pada pengujian dengan 3 *input layer*, 12 *hidden layer*, nilai 1 *output*, dan momentum 0,9 dengan *learning rate* 0,5. Dari target SSE 0,1, didapatkan nilai SSE 0,302868.

Peneliti Nguyen dkk (2020) melakukan penelitian dalam memprediksi dan mengukur curah hujan harian/bulanan menggunakan 6 variabel yaitu: suhu, titik embun, kelembaban, tekanan udara, visibilitas dan kecepatan angin. Hasil penelitian menunjukkan model ANN dapat melakukan prediksi dengan baik. Nilai RMSE pada prediksi curah hujan harian menghasilkan 0,2487, sedangkan RMSE untuk prediksi curah hujan bulanan menghasilkan 0,0731. Akurasi pada prediksi curah hujan bulanan lebih tinggi dibandingkan dibandingkan curah hujan harian.

2.2 Prediksi

Dalam Kamus Besar Bahasa Indonesia disebutkan bahwa prediksi adalah hasil dari kegiatan memprediksi, meramal, memperkirakan nilai di masa depan dengan menggunakan data di masa lalu. Menurut Jay Heizer, Render, & Munson (2017) prediksi merupakan kombinasi seni dan ilmu memperkirakan peristiwa masa depan atau kondisi menggunakan model matematika atau perkiraan secara subyektif dengan data yang sudah ada di masa lalu.

Prediksi adalah usaha untuk memperkirakan apa yang akan terjadi di masa depan dengan memanfaatkan data yang relevan dari masa lalu (historis) yang diperoleh dengan menggunakan metode ilmiah. Prediksi dilakukan untuk mempelajari apa yang mungkin terjadi di masa depan. Metode peramalan dapat diterapkan secara kuantitatif melalui perhitungan matematis atau secara kualitatif (Nurmahaludin, 2014).

Beberapa sumber informasi yang dapat digunakan dalam melakukan prediksi, bergantung pada apa yang ingin diramalkan. Untuk prediksi cuaca, sumber informasi bisa berupa data tentang kondisi cuaca saat ini, seperti tekanan udara,

kelembaban, dan temperatur. Data ini dapat diperoleh dari stasiun BMKG. Dalam melakukan prediksi terhadap curah hujan selama ini BMKG menggunakan metode subyektif, yaitu prediksi yang dibuat berdasarkan pertimbangan atau penilaian prakirawan (Merdekawati & Ismail, 2019).

2.3 Curah Hujan

Curah hujan adalah jumlah total air hujan yang jatuh di suatu daerah yang datar dan tidak mengalir (tenang). Di Indonesia, satuan pengukuran curah hujan lebih umum dinyatakan dalam millimeter. Ketika Hujan satu milimeter atau lebih, itu menunjukkan bahwa satu meter persegi tanah datar ditutupi dengan air hingga kedalaman satu milimeter atau satu liter atau lebih dari air yang terkumpul (Soewarno, 2015).

Curah hujan merupakan jumlah air hujan yang jatuh pada suatu daerah tertentu selama periode waktu tertentu. Curah hujan ini diukur setiap hari, setiap bulanan dan tahunan dalam milimeter atau sentimeter. Beberapa faktor seperti : topografi, arah kemiringan medan, arah angin, dan kecepatan angin dapat mempengaruhi curah hujan (Mukid & Sugito, 2013).

Menurut BMKG (2008), Curah hujan memiliki satuan dalam milimeter. Curah hujan 1 (satu) milimeter adalah air hujan yang jatuh pada ketinggian 1mm seluas 1 m² tidak menguap, meresap atau mengalir. Atau Sejumlah air hujan yang jatuh sebanyak 1 liter pada setiap luasan 1 m². Sebagai ilustrasi:

- a. Curah hujan 10 mm pada luasan 100 m² = 1000 liter air = 1 meter kubik air
- b. Curah hujan 100 mm pada luasan 1 Km = 100 juta liter air = 100 ribu meter kubik air

Klasifikasi besar curah hujan bulanan menurut BMKG (2010) adalah sebagai berikut:

- a. Rendah → 0-100 mm/bulan
- b. Sedang → 100-300 mm/bulan
- c. Tinggi → 300-500 mm/bulan
- d. Sangat Lebat → > 500 mm/bulan

Menurut Badwi, Maru, & Abbas (2017) terdapat banyak faktor yang dapat mempengaruhi banyak sedikitnya curah hujan, diantaranya:

1. Suhu

Salah satu faktor yang mempengaruhi curah hujan adalah suhu. Daerah dengan suhu rendah mengalami curah hujan yang rendah. Di sisi lain, daerah dengan suhu tinggi memiliki curah hujan yang tinggi (Aini, 2021)

2. Kelembaban

Semakin tinggi kelembaban maka curah hujan akan tinggi, jika kelembaban rendah maka curah hujan akan rendah pula (Zubair, Tjaronge, & Ramli, 2016).

3. Ketinggian Tempat

Faktor yang berpengaruh signifikan adalah ketinggian. Hal ini karena curah hujan bergantung pada ketinggian. Daerah yang mengalami lebih banyak curah hujan berada pada daerah yang tinggi dibandingkan daerah yang lebih rendah, Sebaliknya, curah hujan akan sedikit jika pada tempat yang lebih rendah. Hal ini disebabkan bahwa ketinggian tempat juga dipengaruhi oleh suhu udara (Fatma, 2018).

4. Luas lahan hijau

Keadaan suhu udara dan kelembaban di suatu daerah berkorelasi dengan keberadaan ruang terbuka hijau. Semakin baik kondisi ruang terbuka hijau, semakin tinggi kelembaban dan semakin rendah suhu, maka curah hujan juga rendah (Zubair et al., 2016).

5. Luas wilayah

Luas lahan juga merupakan penentu curah hujan di suatu tempat. Hal ini dikarenakan wilayah daratan yang lebih luas akan memiliki titik tengah yang menjauhi lautan sebagai pusat penguapan air hujan. Artinya, potensi hujan di wilayah tersebut akan lebih kecil. Sebaliknya, daratan yang sempit akan lebih dekat dengan lautan sebagai tempat terjadinya penguapan, sehingga akan lebih sering terjadi hujan (Aini, 2021).

6. Jarak dari sumber air

Penguapan dari sumber air atau laut mempengaruhi banyaknya curah hujan di suatu tempat. Karena awan kondensasi akan mencari tempat di dekat laut sebelum mencapai tempat yang lebih jauh, Semakin dekat suatu tempat dengan laut, semakin banyak jumlah hujan yang turun (Fatma, 2018).

7. Deret pegunungan

Banyaknya deret pegunungan merupakan salah satu faktor tinggi rendahnya curah hujan. Pegunungan bertindak sebagai penghalang fisik terhadap kecepatan angin. Hujan orografis yang menyebabkan curah hujan lebih tinggi di sisi angin dan gunung di sebelahnya (*leeward*) dan curah hujan akan sangat rendah apabila berada di sisi angin dan gunung bawahnya (Tukidi, 2010).

8. Ketersediaan air

Curah hujan yang tinggi ataupun rendah akan berdampak pada ketersediaan air. Pasokan air terbatas karena curah hujan yang rendah. Kekeringan akan terjadi jika pasokan air semakin sedikit dan berlanjut cukup lama. (H. H. Siregar, Pawitan, Boer, & Yahya, 2003). Menurut Hamdani & Susanti (2017) ketersediaan air secara meteorologis dapat dihitung berdasarkan jumlah rata-rata curah hujan dan luas wilayah terbuka hijau.

Ketersediaan air meteorologis = $\sum \text{curah hujan} \times \text{Luas wilayah ruang terbuka hijau}$


2.4 Artificial Neural Network (ANN)

Metode pemrosesan informasi yang disebut Jaringan Saraf Tiruan (ANN) dimodelkan setelah sistem saraf biologis, seperti otak manusia. Struktur sistem pemrosesan informasi, yang terdiri dari banyak elemen pemrosesan (neuron) yang digabungkan dan bekerja sama untuk memecahkan masalah tertentu, adalah kunci untuk memahami pola ini (Andrian & Ningsih, 2014).

Model komputasi yang meniru bagaimana fungsi neuron alami yang disebut dengan *Artificial Neural Network* (ANN). Neuron menjadi aktif ketika menerima input dan mengirimkan sinyal yang kemungkinan akan mengaktifkan neuron lain. Untuk menghitung aktivasi neuron, fungsi matematika diterapkan pada input yang dikalikan dengan berat dalam ANN. Perhitungan Neuron dapat dipengaruhi oleh bobot yang digunakan. Kita bisa mendapatkan output yang diinginkan untuk input yang diberikan dengan mengubah berat neuron buatan (Gershenson, 2009).

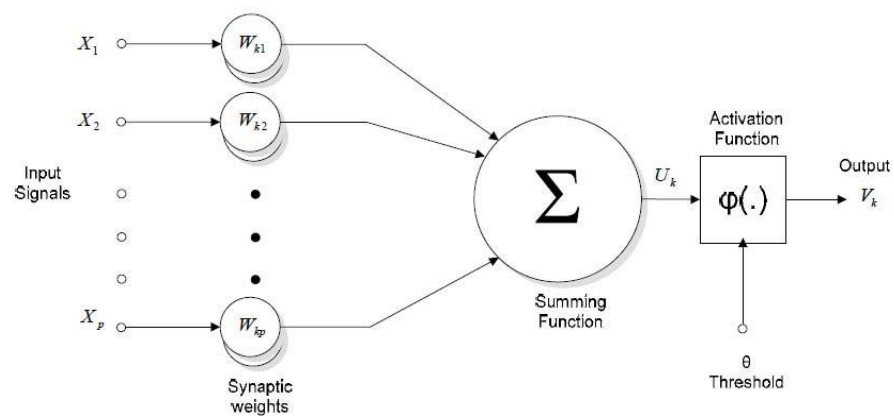
2.4.1 Arsitektur ANN

Basheer dan Hajmeer (2000) berpendapat bahwa jaringan saraf tiruan dapat diilustrasikan sebagai node x mewakili akson dan dendrit, sedangkan bobot koneksi mewakili sinapsis dan ambang batas mendekati aktivitas di soma. Proses yang terjadi dimulai dari n neuron biologis dengan berbagai sinyal intensitas x dan kekuatan sinaptik w memberi makan ke neuron dengan ambang batas b , dan sistem neuron buatan yang setara seperti Gambar 2.1 berikut.



Gambar 2.1 Interaksi Sinyal dari n Neuron dan Analogi dengan Penjumlahan Sinyal dalam Neuron Buatan terdiri dari Perceptron Lapisan Tunggal (Sumber: Basheer & Hajmeer, 2000)

Amrizal & Aini (2013) berpendapat bahwa komponen neuron pada jaringan saraf tiruan secara matematis dapat dilihat pada Gambar 2.2 berikut.



Gambar 2.2 Komponen Matematis Neuron (Sumber: Amrizal & Aini, 2013)

Neuron pada Gambar 2.2 menyerupai neuron biologis yang ditemukan pada manusia. Neuron terdiri dari tiga komponen: *output*, fungsi penjumlahan (fungsi sumatif) dan fungsi aktivasi. Neuron buatan yang terlihat di atas menyerupai neuron biologis saat diperiksa. Neuron menerima informasi (*input*) dengan bobot tertentu. Fungsi kemudian melakukan proses dengan menambahkan nilai bobot yang telah ditentukan ke dalam *input*. Hubungan antara neuron menentukan bobot. Melalui fungsi aktivasi setiap neuron, hasil jumlah dibandingkan dengan nilai ambang (*threshold*). Jika neuron diaktifkan, semua neuron yang memenuhi syarat akan menerima output melalui bobot output.

Menurut Amrizal & Aini (2013) setiap informasi *input* dan *output* yang dimasukkan ke dalam JST dioperasikan oleh neuron. Lapisan yang terdiri dari neuron ini dikenal sebagai lapisan neuron. Tiga lapisan yang membentuk JST dapat dipisahkan menjadi:

1. Lapisan masukan (*Input Layer*)


Unit di lapisan *input* disebut unit *input*. Unit input ini menerima pola input data yang menentukan masalah dari luar.

2. Lapisan tersembunyi (*Hidden Layer*)

Unit tersembunyi (*hidden*) adalah sebutan dari unit pada lapisan tersembunyi, namun hasil *output* tidak bisa diamati secara terbuka.

3. Lapisan keluaran (*Output Layer*)

Unit *output* merupakan sebutan dari unit pada lapisan *output*. Keluaran dari lapisan ini adalah solusi jaringan saraf tiruan dari suatu masalah.




Gambar 2.3 Arsitektur Neural Network (Sumber: McKee, Harmanto, & Whitbrook, 2018)

Pada Gambar 2.3 menunjukkan cara kerja jaringan saraf tiruan, di mana neuron akan dikumpulkan dalam lapisan yang disebut lapisan neuron (*neuron layer*). Biasanya, neuron-neuron dalam suatu lapisan terhubung dengan lapisan sebelumnya dan setelahnya (kecuali lapisan *input* dan lapisan *output*). Informasi akan merambat dari lapisan ke lapisan di dalam jaringan saraf tiruan, mulai dari lapisan *input* ke lapisan *output* melalui lapisan lain yang disebut lapisan tersembunyi (*hidden layer*), sesuai dengan algoritma pembelajaran. Informasi juga dapat secara otomatis dikirim kembali ke lapisan jaringan (Amrizal & Aini, 2013).

Haykin (2009) menyatakan bahwa ANN memiliki berbagai macam arsitektur yang sering digunakan, yaitu:

1. *Single Layer Network* (Jaringan dengan Lapisan Tunggal)

Dalam jaringan lapisan tunggal, terdapat lapisan bobot koneksi terbaik. Ketika menerima sinyal dari luar, unit *input* akan aktif. Sedangkan untuk membaca *respons* jaringan, unit *output* yang berperan aktif. Unit *input* terhubung ke seluruh unit *output*, tetapi tidak terhubung ke unit *input* yang lain pada lapisan yang sama. Gambar 2.4 menunjukkan struktur *single layer* di mana X merupakan *input layer* dan Y merupakan *output layer*.



Gambar 2.4 Single Layer Network (Sumber: kajianpustaka.com)

Keterangan:

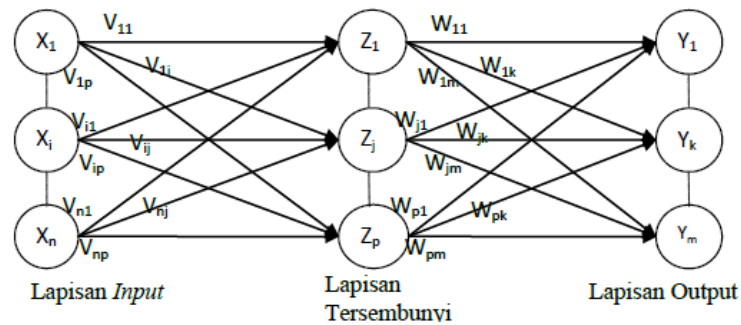
X_n : Data masukan (*input layer*)

W_{nj} : Bobot ke simpul *output*

Y_m : Hasil Keluaran (*output*)

2. Multilayer Network (Jaringan dengan Lapisan Banyak)

Sebuah Jaringan lapisan banyak terdiri dari satu atau lebih lapisan tambahan (bertingkat) node (disebut sebagai perangkat tersembunyi) di antara unit *input* dan unit *output* sering disebut dengan jaringan *multilayer*. Seperti yang terlihat pada Gambar 2.5, biasanya terdapat bobot diantara dua unit yang berdekatan (*input*, *hidden*, dan *output*).



Gambar 2.5 Multilayer Network (Sumber: Sagar & Kumar, 2014)

Keterangan:

- X_i : Data masukan (*input layer*)
- V_{nj} : Bobot ke simpul *hidden*
- W_{ij} : Bobot ke simpul *output*
- Z_j : *Hidden Layer*
- Y_k : Hasil Keluaran (*output*)

Jaringan *multilayer* mampu memecahkan masalah yang lebih kompleks daripada jaringan *single layer*, tetapi pada pelatihannya mungkin lebih sulit. Namun, dalam beberapa kasus, pelatihan mungkin lebih berhasil, karena jaringan *multilayer* kebanyakan lebih mampu menyelesaikan masalah yang tidak dapat diselesaikan oleh jaringan *single layer*.

2.4.2 Algoritma Backpropagation Neural Network (BPNN)

Backpropagation adalah salah satu model pembelajaran jaringan saraf tiruan dengan kemampuan untuk mencapai keseimbangan antara kapasitas jaringan untuk mendeteksi pola dari pelatihan dan kapasitasnya agar jaringan memberikan respon yang tepat terhadap pola masukan yang terkait tetapi berbeda dengan pola yang digunakan saat proses pelatihan (Kusmaryanto, 2014).

Pelatihan pada BPNN memiliki 3 tahap yaitu tahap maju (*feedforward*), tahap mundur (*backforward*) dan tahap modifikasi bobot. Pada tahap *feedforward*, pola *input* dihitung dari lapisan *input* maju ke lapisan *output*. Pada tahap

backward, setiap unit *output* menerima pola target yang terkait dengan pola *input* untuk menghitung nilai kesalahan. Tahap modifikasi bobot bertujuan untuk mengurangi kesalahan yang terjadi. Ketiga tahap ini diulang sampai kondisi terminasi terpenuhi (Nurmila, Sugiharto, & Sarwoko, 2010).

Langkah-langkah pembelajaran algoritma *backpropagation* menurut Fausset (1994) sebagai berikut:

Tahap inisialisasi

Langkah 0 : Inisialisasi bobot (dapatkan bobot awal dengan nilai random yang cukup kecil seperti angka -1 hingga 1).

Tetapkan maksimum *Epoch*, Target Error dan Learning Rate.

Inisialisasi Epoch = 0, MSE = 1.

Langkah 1 : Kerjakan Langkah-langkah selanjutnya selama (*Epoch* < Maksimum *Epoch*) dan (MSE > Target Error). *Epoch* = *Epoch* + 1.

Langkah 2 : Masing-masing pasangan elemen akan dilakukan pembelajaran, kemudian kerjakan langkah-langkah selanjutnya.

Fase I Feedforward

Langkah 3 : Masing- masing unit *input* ($X_i, i=1, 2, 3, \dots, n$) menerima sinyal X_i dan meneruskan sinyal tersebut ke seluruh unit pada susunan yang terdapat di atasnya (susunan tersembunyi).

Langkah 4 : Masing- masing unit tersembunyi ($Z_{net\ j}, j=1, 2, 3, \dots, p$) menjumlahkan sinyal- sinyal *input* terbobot:

$$Z_{net\ ij} = v_{0j} + \left(\sum_{i=1}^n x_i * v_{ij} \right) \quad (2.1)$$

Keterangan:

$Z_{net\ ij}$ = nilai untuk menghitung *hidden layer*

x_{ij} = nilai *input layer* ke i
 v_{ij} = bobot antara *input layer* dan *hidden layer*
 v_{0j} = bobot bias antara *input layer* dan *hidden layer*

Untuk menghitung sinyal *output* maka digunakan fungsi aktivasi:

$$Z_{ij} = f(z_{net\ ij}) = \frac{1}{1+e^{-z_{net\ ij}}} \quad (2.2)$$

Keterangan:

Z_{ij} = nilai aktivasi dari unit $Z_{net\ ij}$
 $Z_{net\ ij}$ = nilai untuk menghitung *hidden layer*

Kemudian mengirimkan sinyal tersebut ke semua unit di lapisan

atasnya (unit- unit *output*). Menghitung unit Y_{jk} ($jk = 1, 2, 3, \dots, n$)

$$Y_{net\ jk} = w_{0k} + \left(\sum_{j=1}^n w_{jk} * Z_{ij} \right) \quad (2.3)$$

Keterangan:

$Y_{net\ jk}$ = *input* untuk unit Y_{jk}
 w_{0k} = nilai bobot sambungan pada bias untuk unit Y_{jk}
 w_{jk} = nilai bobot sambungan dari Z_{ij} ke unit Y_{jk}

Menghitung keluaran menggunakan aktivasi pada persamaan 2.4

$$Y_{jk} = f(Y_{net\ jk}) = \frac{1}{1 + e^{-Y_{net\ jk}}} \quad (2.4)$$

Keterangan:

Y_{jk} = nilai *output layer*
 $Y_{net\ jk}$ = *input* untuk unit Y_{jk}

Fase II Backward

Langkah 5 : Masing-masing unit *output* ($Y_{jk}, jk = 1, 2, 3, \dots, m$) menerima

target yang berhubungan dengan pola *input* pembelajaran

kemudian hitung informasi errornya:

$$\delta_{jk} = (Y'_{jk} - Y_{jk})f'(Y_{ink}) = (Y'_{jk} - Y_{jk})Y_{jk}(1 - Y_{jk}) \quad (2.5)$$

Keterangan:

δ_{jk} = nilai kesalahan pada *output layer*

Y'_{jk} = nilai target data

Y_{jk} = nilai *output*

Hitung koreksi bobot (yang akan digunakan untuk memperbaiki

nilai W_{ij}):

$$\Delta w_{jk} = \alpha \delta_k z_{ij} \quad (2.6)$$

Keterangan:

Δw_{jk} = selisih antara $w_{jk}(t)$ dengan $w_{jk}(t+1)$

α = nilai *learning rate*

δ_{jk} = nilai kesalahan *output layer*

Z_{ij} = nilai aktivasi dari unit $Z_{net\ ij}$

Hitung koreksi pada bias (yang akan digunakan untuk

memperbaiki nilai w_{0k}):

$$\Delta w_{0k} = \alpha \delta_{jk} \quad (2.7)$$

Keterangan:

Δw_{0k} = selisih antara $w_{0k}(t)$ dengan $w_{0k}(t+1)$

α = nilai *learning rate*

δ_{jk} = nilai kesalahan *output layer*

Langkah 6 : Masing-masing unit tersembunyi Z_{ij} ($ij=1,2,\dots,p$) menjumlahkan

data *inputnya* (dari unit-unit pada lapisan atasnya):

$$\delta_{net\ jk} = \left(\sum_{k=1}^m \delta_{jk} * w_{jk} \right) \quad (2.8)$$

Keterangan:

$\delta_{net\ ij}$ = nilai untuk menghitung nilai kesalahan pada *hidden layer*

w_{jk} = bobot dari Z_{ij} ke Y_{jk}

Kalikan dengan turunan dari fungsi aktivasinya agar diketahui

informasi *errornya*:

$$\delta_{ij} = \delta_{net\ jk} f'(Z_{net\ ij}) = \delta_{net\ jk} \quad (2.9)$$

Keterangan:

δ_{ij} = nilai aktivasi untuk menghitung nilai kesalahan pada *hidden layer*

Hitung koreksi bobot (yang akan digunakan untuk memperbaiki nilai v_{ij}):

$$\Delta v_{ij} = \alpha \delta_{ij} x_{ij} \quad (2.10)$$

Keterangan:

Δv_{ij} = selisih antara $v_{ij}(t)$ dengan $v_{ij}(t+1)$

α = nilai *learning rate*

δ_{ij} = nilai kesalahan *hidden layer*

x_{ij} = unit ke-i pada *input layer*

Hitung koreksi bias (yang akan digunakan dalam untuk memperbaiki nilai V_{0j}):

$$\Delta V_{0j} = \alpha \delta_{ij} \quad (2.11)$$

Keterangan:

Δv_{0j} = selisih antara $v_{0j}(t)$ dengan $v_{0j}(t+1)$

α = nilai *learning rate*

δ_{ij} = nilai kesalahan *hidden layer*

Update bobot dan bias

Langkah 7 : Masing-masing unit *output* ($Y_{jk}, jk = 1, 2, \dots, m$) memperbaiki bias dan bobotnya ($j=0, 1, 2, \dots, p$):

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.12)$$

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

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (2.13)$$

Langkah 8 : Hitung nilai MSE


Dari bobot-bobot yang telah dihasilkan akan digunakan sebagai bobot awal untuk proses *epoch* selanjutnya. Langkah-langkah

didasarkan merupakan siklus pelatihan untuk satu kali (*satu epoch*). Proses pelatihan diulang hingga mencapai target error sekecil mungkin (*maksimum epoch*). Hasil akhir dari pelatihan jaringan ini berupa bobot-bobot w_1, \dots, w_n yang akan disimpan untuk pengujian jaringan.

2.4.3 Fungsi Aktivasi

Menurut Julpan, Nababan, dan Zarlis (2015) fungsi aktivasi dalam jaringan saraf merupakan fungsi yang akan mengontrol neuron akan aktif atau tidak. Fungsi aktivasi *backpropagation* perlu memiliki karakteristik tertentu, seperti : tidak menurun secara monotonis (*monoton non-decreasing*), kontinu, dan differensial. Selain itu, fungsi yang tersedia kemudian diproses ulang, dan fungsi aktivasi itu sendiri dapat digunakan untuk mewakili nilai yang dihasilkan. Menurut Kusumadewi (2004) fungsi sigmoid biner (logsig) sangat ideal untuk ANN ketika algoritma pembelajaran menggunakan metode *backpropagation*. Persamaan 2.14 mempresentasikan Fungsi biner sigmoid memiliki rentang (0,1) dan sesuai untuk jaringan dengan nilai keluaran antara 0 dan 1 seperti yang ditunjukkan pada Gambar 2.6 berikut.

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2.14)$$



Gambar 2.6 Fungsi aktivasi (Sumber: Fausset, 1994)

2.4.4 Normalisasi Data

Han & Kamber (2006) berpendapat bahwa normalisasi adalah proses penyesuaian data sehingga berada pada skala kisaran nilai yang lebih kecil antara 0 dan 1. Normalisasi ini dilakukan karena data akan melalui fungsi aktivasi sigmoid dimana nilainya juga berkisar antara 0 dan 1. Hasil dari normalisasi data dapat digunakan untuk membandingkan keakuratan nilai prediksi dan nilai aktual. Rumus perhitungan normalisasi data ditunjukkan pada persamaan 2.15.

$$v_i' = \frac{(v_i - \min_A)}{(max_A - \min_A)} (new_max_A - new_min_A) + (new_min_A) \quad (2.15)$$

Keterangan:

v_i'	= data hasil normalisasi
v_i	= data asli
max_A	= data asli terbesar
min_A	= data asli terkecil
new_max_A	= data terbesar yang baru ditentukan (0,9)
new_min_A	= data terkecil yang baru ditentukan (0,1)

Menurut Han & Kamber (2006) normalisasi data juga dapat dilakukan menggunakan rumus z score ditunjukkan oleh persamaan 2.16.

$$v_i' = \frac{(v_i - A)}{\sigma_A} \quad (2.16)$$

Keterangan:

v_i'	= data hasil normalisasi
v_i	= data asli
A	= rata-rata (mean)
σ_A	= standar deviasi

2.4.5 Denormalisasi Data

Menurut Fadhilah & Ginardi (2017) denormalisasi adalah proses pengembalian nilai hasil normalisasi ke nilai aslinya dengan tujuan mendapat nilai yang sebenarnya. Denormalisasi dilakukan setelah melakukan normalisasi data. Rumus denormalisasi ditunjukkan pada persamaan 2.17.

$$v_i = \frac{(v_i' - \text{new_min}_A)(\text{max}_A - \text{min}_A)}{(\text{new_max}_A - \text{new_min}_A)} + \text{min}_A \quad (2.17)$$

Keterangan:

v_i	= data asli
v_i'	= data hasil normalisasi
max_A	= data asli terbesar
min_A	= data asli terkecil
new_max_A	= data terbesar yang baru ditentukan (0,9)
new_min_A	= data terkecil yang baru ditentukan (0,1)

Denormalisasi juga dapat dilakukan dengan menggunakan rumus pada persamaan

$$2.18. \quad v_i = (v_i' \times \sigma_A) + A \quad (2.18)$$

Keterangan:

v_i	= data asli
v_i'	= data hasil normalisasi
A	= rata-rata (mean)
σ_A	= standar deviasi

2.4.6 Nilai MSE

Mean Square Error (MSE) adalah Selisih kuadrat rata-rata antara nilai sebenarnya dan nilai yang diperkirakan. Saat menentukan nilai prediktif, MSE sering digunakan untuk menilai kesalahan rata-rata. Nilai MSE yang rendah atau nilai MSE yang mendekati nol menunjukkan bahwa hasil prakiraan tersebut akurat dan dapat digunakan sebagai dasar perhitungan prediksi masa depan. (James, Witten, Hastie, & Tibshirani, 2012). Adapun rumus perhitungan MSE ditunjukkan oleh persamaan 2.19 berikut:

$$MSE = \frac{\sum_{i=1}^n (y_i - t_i)^2}{n} \quad (2.19)$$

Keterangan:

y_i	= nilai ke-i sesungguhnya
t_i	= nilai prediksi ke-t
n	= banyaknya data

2.4.7 Nilai MAPE

Lewis (1982) mendefinisikan MAPE (*Mean Absolute Percentage Error*) sebagai persentase kesalahan rata-rata yang bersifat mutlak (absolute). MAPE digunakan untuk mengevaluasi ketepatan prakiraan atau prediksi yang dibuat dengan menggunakan teknik peramalan. Metode *Mean Absolute Percent Error* (MAPE) mengungkapkan berapa banyak kesalahan perkiraan atau perkiraan dibandingkan dengan nilai aktual data. Rumus perhitungan MAPE ditunjukkan oleh persamaan 2.20.

$$MAPE = \frac{\sum_{t=1}^n \left| \left(\frac{A_t - F_t}{A_t} \right) \times 100 \right|}{n} \quad (2.20)$$

Keterangan:

A_t = nilai ke-i sesungguhnya
 F_t = nilai prediksi ke-t
 N = banyaknya data

Semakin kecil persentase kesalahan dalam MAPE, semakin akurat prediksinya.

Nilai MAPE dapat dikategorikan menjadi beberapa kategori berdasarkan nilainya, dapat dilihat pada Tabel 2.1 berikut.

Tabel 2.1 Klasifikasi MAPE (Sumber: Lewis, 1982)

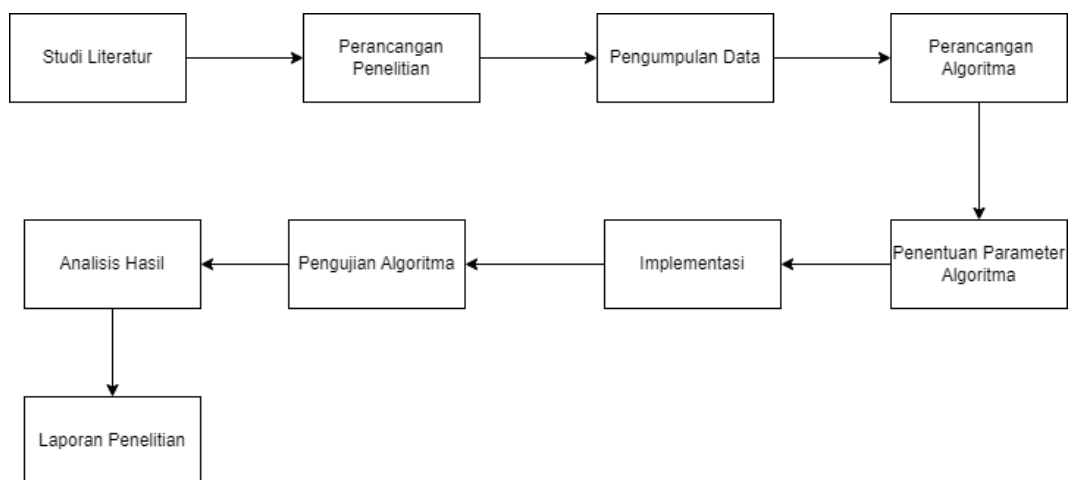
MAPE	Kategori Peramalan
<10%	Sangat Akurat (<i>Excellent</i>)
10% - 20%	Baik (<i>Good</i>)
20% - 50%	Wajar (<i>Reasonable</i>)
>50%	Tidak Akurat (<i>Inaccurate</i>)

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Prosedur Penelitian

Dalam penelitian ini dilakukan beberapa tahapan yang dilakukan secara runtut dan sistematis sehingga memudahkan penulis dalam menentukan langkah selanjutnya sehingga mendapatkan hasil yang diharapkan. Adapun diagram blok prosedur penelitian ditunjukkan pada Gambar 3.1 berikut.



Gambar 3.1 Diagram Blok Prosedur Penelitian

Tahapan awal dalam penelitian ini adalah studi literatur, yaitu mencari, mendapatkan dan melengkapi pengetahuan dasar terkait teori-teori penelitian sebelumnya berupa jurnal, *e-book* mengenai topik-topik mengenai prediksi atau peramalan curah hujan, penghitungan curah hujan, algoritma jaringan saraf tiruan (ANN) hingga metode *backpropagation* (Rachman, Cholissodin, & Fauzi, 2018). Tahap kedua adalah perancangan penelitian dengan melakukan persiapan yang dimulai dari sumber data, komponen pendukung seperti PC beserta software program yang akan digunakan. Setelah rancangan selesai dibuat, maka dilakukan pengumpulan data pada tahap ketiga. Pengumpulan data dilakukan dengan cara

scrapping secara manual melalui website resmi BPS Jawa Timur. Data yang didapatkan kemudian dikumpulkan dan dipilah-pilah sesuai dengan kebutuhan agar dapat diolah pada tahap selanjutnya. Tahap keempat yaitu penentuan parameter algoritma. Program yang membantu dalam proses pembangunan algoritma adalah *google colab*. Setelah program selesai dibangun, maka dilakukan tahap kelima yaitu pengujian algoritma secara bertahap dengan tujuan untuk mengetahui apakah algoritma sudah berjalan sesuai dengan yang diharapkan atau belum. Tahap keenam adalah analisis hasil, jika algoritma berjalan dengan baik maka akan menghasilkan data sesuai dengan yang diharapkan. Analisis dengan hasil terbaik dari setiap pemodelan pada beberapa parameter kemudian dibandingkan setiap hasilnya. Apabila sudah ditemukan maka dapat ditarik kesimpulan dengan menuliskannya dalam laporan hasil dengan menyertakan keterangannya.

3.2 Data yang digunakan

Data yang digunakan dalam penelitian ini berupa data sekunder yang diambil dari website bps pada beberapa kabupaten/kota <https://www.bps.go.id> diantaranya: suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut, ketersediaan air dan curah hujan pada kecamatan di Jawa Timur yang meliputi Kabupaten Malang, Kota Malang, Kota Batu, Kabupaten Pasuruan, Kota Pasuruan, Kabupaten Madiun, Kota Madiun, Kabupaten Tulungagung dan Kabupaten Blitar periode 2017 hingga 2021. Contoh data curah hujan di wilayah kecamatan di Jawa Timur dapat dilihat pada Tabel 3.1 berikut.

Tabel 3.1 Contoh Data Curah Hujan dan Faktor Penentu Curah Hujan Kecamatan di Jawa Timur Periode 2017

Nama Kecamatan	Suhu Rata-rata (°C)	Kelembapan (%)	Ketinggian (mdpl)	Luas lahan hijau (ha)	Jarak dari laut (km)	Jumlah gunung	Ketersediaan Air (juta m ³ /Tahun)	Luas Wilayah (km ²)	Curah Hujan (mm/Tahun)
Kauman	21,00	94,00	90,00	1944,00	23,94	0	4.440,96	30,84	144,0000
Gondang	21,00	94,00	96,00	2316,00	21,30	0	6.735,06	44,02	153,00
Pagerwojo	21,00	94,00	476,00	4711,00	32,43	1	20.290,60	88,22	230,00
Sendang	21,00	94,00	493,00	5993,00	31,82	0	26.140,66	96,46	271,00
Bakung	21,00	94,00	160,00	4633,00	2,24	1	6.785,64	111,24	61,00
Wonotirto	21,00	94,00	387,00	10304,00	7,43	1	15.494,73	164,54	94,17
Panggunrejo	21,00	94,00	310,00	8170,00	7,72	0	17.895,68	119,04	150,33
Wates	21,00	94,00	420,00	4860,00	6,49	1	6.472,17	68,76	94,13
Binangun	21,00	94,00	243,00	5400,00	10,87	0	11.883,25	76,79	154,75
Sutojayan	21,00	94,00	150,00	2038,00	17,48	0	7.944,95	44,20	179,75
Kademangan	21,00	94,00	246,00	5081,00	13,07	0	10.738,56	105,28	102,00
Kanigoro	21,00	94,00	183,00	4243,00	21,60	0	6.777,10	55,55	122,00
Talun	21,00	94,00	221,00	2750,00	22,49	0	5.774,48	49,78	116,00
Selopuro	21,00	94,00	192,00	1941,00	20,79	0	3.698,25	39,29	94,13
Kesamben	21,00	94,00	222,00	3614,00	20,34	3	7.803,52	56,96	137,00
Selorejo	21,00	94,00	293,00	3011,00	23,80	0	12.156,53	52,23	232,75
Doko	21,00	94,00	349,00	5076,00	32,91	2	10.358,70	70,95	146,00
Wlingi	21,00	94,00	282,00	4037,00	28,10	2	10.750,32	66,36	162,00
Gandusari	21,00	94,00	348,00	5632,00	31,69	2	8.470,08	88,23	96,00
Garum	21,00	94,00	276,00	4010,00	31,30	1	7.529,28	54,56	138,00
Nglegok	21,00	94,00	325,00	7239,00	35,53	2	24.404,99	92,56	263,67
Sanankulon	21,00	94,00	212,00	2215,00	27,55	0	7.654,79	33,33	229,67
Ponggok	21,00	94,00	162,00	5062,00	34,18	1	10.902,15	103,83	105,00
Srengat	21,00	94,00	133,00	2354,00	26,59	2	6.909,44	53,98	128,00
Wonodadi	21,00	94,00	105,00	2885,00	26,12	0	4.156,05	40,35	103,00
Udanawu	21,00	94,00	123,00	3352,00	31,64	0	6.720,72	40,98	164,00

Terdapat beberapa data parameter suhu, kelembaban dan curah hujan yang tidak tersedia pada setiap kecamatan dalam bps karena keterbatasan stasiun pengamatan iklim. Hal ini mengakibatkan data parameter suhu, kelembaban dan curah hujan didapatkan dari bps kabupaten dengan mencari rata-rata per-tahunnya. Namun untuk memastikan apakah data rata-rata tersebut dapat digunakan, maka

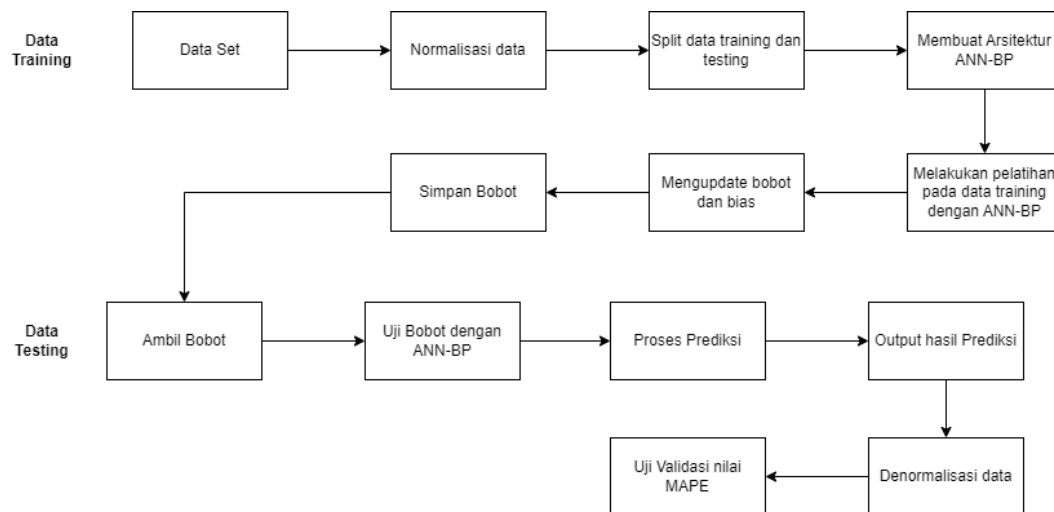
dilakukan perhitungan berdasarkan suhu, kelembaban dengan *output* curah hujan pada setiap kabupaten/kota. Contoh data untuk parameter suhu, kelembaban dan curah hujan pada setiap kabupaten/ kota dapat dilihat pada Tabel 3.2 berikut.

Tabel 3.2 Contoh Data Curah Hujan Berdasarkan Suhu dan Kelembaban pada Kabupaten/Kota di Jawa Timur

Nama Daerah	Suhu (°C)	Kelembaban (%)	Curah Hujan (mm/Tahun)
kota batu	21,67	93,33	170,11
kota batu	21,92	93,58	104,25
kota batu	21,67	94,42	102,58
kota batu	22,50	90,92	140,67
kota batu	22,42	86,83	194,00
kabupaten pasuruan	23,30	86,90	68,00
kabupaten pasuruan	21,90	83,20	231,33
kabupaten pasuruan	21,92	81,67	187,46
kabupaten pasuruan	22,28	85,50	219,77
kabupaten pasuruan	22,94	85,68	336,08
kota pasuruan	23,30	86,90	176,83
kota pasuruan	30,27	84,76	1,00
kota pasuruan	21,92	84,67	8,17
kota pasuruan	22,28	85,50	43,50
kota pasuruan	22,94	85,68	23,18

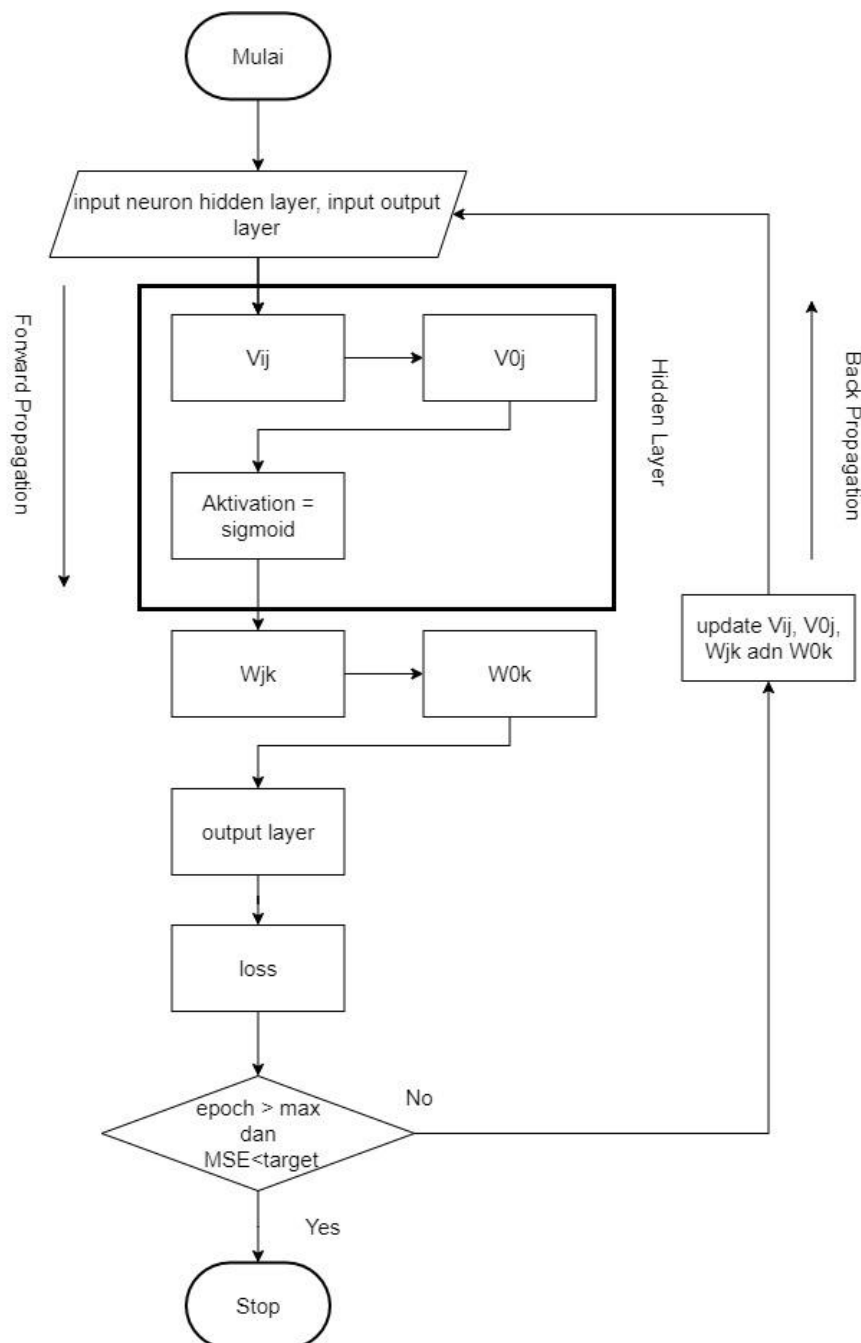
3.3 Desain Sistem

Sistem yang akan digambarkan adalah sistem prediksi curah hujan dengan menggunakan *backpropagation*. Sistem tersebut memerlukan data seperti: suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut dan ketersediaan air. Dengan menggunakan *backpropagation*, diharapkan sistem yang dibangun dapat memberikan hasil prediksi curah hujan yang akurat dimulai dengan menentukan jumlah *input data* yang digunakan, jumlah *hidden layer* (lapisan tersembunyi) yang digunakan dan jumlah *output* yang diinginkan. Diagram blok algoritma jaringan saraf tiruan dapat dilihat pada Gambar 3.2 berikut.



Gambar 3.2 Diagram Blok ANN Backpropagation

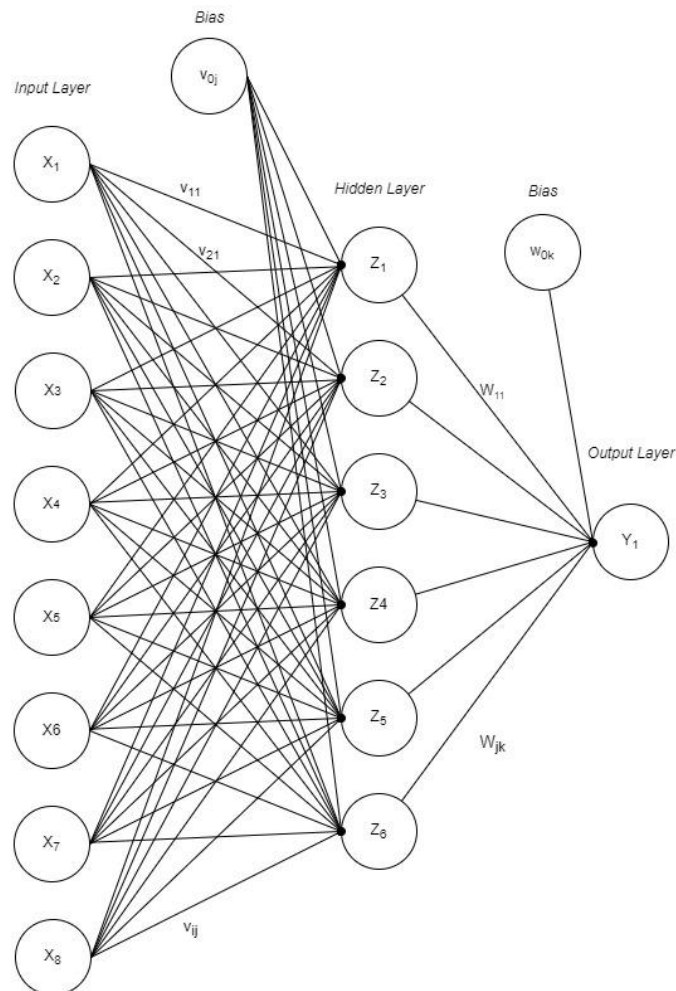
Sistem yang akan dibuat mengimplementasikan algoritma *backpropagation neural network* yang digambarkan secara rinci melalui *flowchart* sebagai proses pemecahan masalah (Rachman et al., 2018). *Flowchart* diwakili oleh simbol-simbol yang dapat mewakili langkah-langkah penyelesaian dengan simbol. Langkah pertama yaitu memasukkan jumlah neuron dalam *hidden layer*, jumlah output layer dengan membawa bobot dan bias dari *input layer* ke *hidden layer*. Kemudian melakukan fungsi aktivasi dan menuju *hidden layer*. Setelah itu dilakukan proses perhitungan bobot dan bias yang berbeda menuju *output layer*. Apabila proses menuju *output layer* maka akan muncul nilai loss, apabila epochnya belum maksimal maka kembali ke proses *input* jumlah neuron dalam *hidden layer* dengan melakukan *update* bobot dan bias, namun apabila sudah maksimal maka akan melanjutkan proses prediksi. Setelah proses prediksi maka proses selesai dapat ditunjukkan pada Gambar 3.3 berikut.



Gambar 3.3 Flowchart Tahapan Prediksi menggunakan ANN Backpropagation

Dalam penelitian ini menggunakan beberapa parameter seperti jumlah *input*, jumlah neuron dalam *hidden layer* dan jumlah *epoch*. Data masukan (*input*) berjumlah 8 yaitu berupa suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut dan ketersediaan air. *Hidden layer*

berjumlah 1 dengan keluaran (*output*) berjumlah 1 yaitu curah hujan. Adapun arsitektur ANN yang akan digunakan dalam penelitian ini ditunjukkan pada Gambar 3.4 berikut.



Gambar 3.4 Contoh Arsitektur ANN dengan 8 *Input*, 1 *Hidden Layer* dan 1 *Output*
(Sumber: Andrian & Ningsih, 2014)

Keterangan:

X_1 = Suhu
 X_2 = Kelembaban
 X_3 = Ketinggian
 X_4 = Luas lahan hijau
 X_5 = Jarak dari laut
 X_6 = Jumlah gunung
 X_7 = ketersediaan air
 X_8 = Luas wilayah
 Y_1 = Curah hujan

Z_1 = Neuron ke-1 dalam *hidden layer*
 Z_2 = Neuron ke-2 dalam *hidden layer*
 Z_3 = Neuron ke-3 dalam *hidden layer*
 Z_4 = Neuron ke-4 dalam *hidden layer*
 Z_5 = Neuron ke-5 dalam *hidden layer*
 Z_6 = Neuron ke-6 dalam *hidden layer*

3.4 Preprocessing

Teknik *preprocessing* data dapat meningkatkan kualitas data, sehingga membantu meningkatkan akurasi dan efisiensi proses penambangan selanjutnya. *Preprocessing* data adalah langkah penting dalam proses penemuan pengetahuan, karena keputusan kualitas harus didasarkan pada kualitas data (Merdekawati & Ismail, 2019). Data yang didapatkan dari proses scrapping masih tidak teratur, oleh karena itu dikumpulkan kemudian dikelompokkan kedalam format yang telah disusun sehingga data curah hujan kecamatan di Jawa Timur dapat dibaca dengan baik.

3.4.1 Normalisasi

Penyesuaian data ke skala umum dilakukan agar mendapatkan hasil yang dapat digunakan untuk membandingkan nilai prediksi dengan nilai aktual. Data yang dinormalisasi merupakan interval $[0,1]$ dengan rentang dari fungsi aktivasi sigmoid biner seperti pada persamaan 2.15. Contoh data setelah dilakukan normalisasi ditunjukkan pada Gambar 3.5 berikut.

Nama Daerah	Suhu Rata-rata (°C)	Kelembapan Udara (%)	Ketinggian (mdpl)	Luas Lahan Hijau (ha)	Jarak dari Laut (km)	Jumlah Gunung	Ketersediaan Air (juta m ³ /thn)	Luas Wilayah (km ²)	Curah Hujan (mm/Tahun)
Kauman	21,00	94,00	90,00	1944,00	23,94	0,00	4.440,96	30,84	144,0000
Gondang	21,00	94,00	96,00	2316,00	21,30	0,00	6735,06	44,02	153,00
Pagerwojo	21,00	94,00	476,00	4711,00	32,43	1,00	20290,60	88,22	230,00
Sendang	21,00	94,00	493,00	5993,00	31,82	0,00	26140,66	96,46	271,00
Bakung	21,00	94,00	160,00	4633,00	2,24	1,00	6785,64	111,24	61,00
Wonotirto	21,00	94,00	387,00	10304,00	7,43	1,00	15494,73	164,54	94,17
Panggungrejo	21,00	94,00	310,00	8170,00	7,72	0,00	17895,68	119,04	150,33
Wates	21,00	94,00	420,00	4860,00	6,49	1,00	6472,17	68,76	94,13
Binangun	21,00	94,00	243,00	5400,00	10,87	0,00	11883,25	76,79	154,75
Sutojayan	21,00	94,00	150,00	2038,00	17,48	0,00	7944,95	44,20	179,75
Kademangan	21,00	94,00	246,00	5081,00	13,07	0,00	10738,56	105,28	102,00

(a)

Nama Daerah	Suhu Rata-rata (°C)	Kelembapan Udara (%)	Ketinggian (mdpl)	Luas Lahan Hijau (ha)	Jarak dari Laut (km)	Jumlah Gunung	Ketersediaan Air (juta m ³ /thn)	Luas Wilayah (km ²)	Curah Hujan (mm/Tahun)
Kauman	0,10	0,73	0,14	0,19	0,33	0,10	0,18	0,18	0,40
Gondang	0,10	0,73	0,14	0,21	0,31	0,10	0,22	0,22	0,42
Pagerwojo	0,10	0,73	0,32	0,32	0,42	0,30	0,50	0,38	0,63
Sendang	0,10	0,73	0,32	0,39	0,41	0,10	0,62	0,41	0,74
Bakung	0,10	0,73	0,17	0,32	0,12	0,30	0,23	0,46	0,17
Wonotirto	0,10	0,73	0,28	0,59	0,17	0,30	0,40	0,64	0,26
Panggunrejo	0,10	0,73	0,24	0,49	0,17	0,10	0,45	0,48	0,41
Wates	0,10	0,73	0,29	0,33	0,16	0,30	0,22	0,31	0,26
Binangun	0,10	0,73	0,21	0,36	0,20	0,10	0,33	0,34	0,43
Sutojayan	0,10	0,73	0,17	0,20	0,27	0,10	0,25	0,23	0,49
Kademangan	0,10	0,73	0,21	0,34	0,23	0,10	0,31	0,44	0,28

(b)

Gambar 3.5 Nilai Data Setelah Proses Normalisasi (a) Data Asli (b) Data Hasil Normalisasi

3.4.2 Pembagian Data

Data yang telah dinormalisasi kemudian dibagi menjadi dua yaitu data latihan (*training*) dan data uji (*testing*). Pembagian dilakukan menggunakan 80% data latihan (*training*) digunakan untuk mengatur nilai bobot dan bias dan 20% data uji (*testing*) digunakan untuk menguji keakurasian model yang sebelumnya telah diperoleh dari data latihan (*training*). Dalam penelitian ini total data sebanyak 640 data dengan pembagian sebanyak 512 data untuk data latihan (*training*) dan 128 data untuk data uji (*testing*).

3.4.3 Proses ANN *Backpropagation*

Data masukan (*input*) berjumlah 8 berupa suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut, ketersediaan air dengan keluaran (*output*) berjumlah 1 berupa curah hujan. Data yang diproses berjumlah 512 data untuk data training dan 128 data untuk data testing.

Proses Training Data

Langkah 0. Inisialisasi

Implementasi backpropagation neural network menggunakan google colab dengan bantuan beberapa library.

```
import pandas as pd
import numpy as np
import tensorflow as tf
from tensorflow import keras
```

Membaca data berupa file excel.

```
train_data=pd.read_excel("/content/sample_data/curah_hujan_
_kecamatan.xlsx")
print(train_data)
```

Data yang telah di import kemudian dilakukan proses normalisasi data.

```
data=pd.DataFrame(train_data,columns=['Suhu','Kelembapan',
'Ketinggian','Luas Lahan Hijau','Jarak dari Laut','Jumlah
Gunung','Ketersediaan Air','Luas Wilayah','Curah Hujan'])
normalisasi = ((0.8*(data - data.min()))/(data.max()-
data.min()))+ 0.1
print(normalisasi)
```

Membagi data training dan data testing.

```
data_training=normalisasi.iloc[0:512,:-1]
y_train=normalisasi.iloc[0:512,-1]
data_training,y_train
```

```
data_testing=normalisasi.iloc[512:640,:-1]
y_test=normalisasi.iloc[512:640,-1]
data_testing,y_test
```

Membentuk arsitektur jaringan saraf tiruan menggunakan model keras dengan jumlah neuron dalam *hidden layer* sebanyak 2, *output layer* sebanyak 1 dan learning rate sebesar 0,01. Tidak lupa untuk menambahkan fungsi aktivasi sigmoid dan bias.

```
model = tf.keras.models.Sequential([
    tf.keras.layers.Dense(units= 2, activation='sigmoid'
    , use_bias=True, name='FirstLayer'),
    tf.keras.layers.Dense(units= 1, activation='sigmoid'
    , use_bias=True, name='LastLayer')
])
```

```

opt = keras.optimizers.Adam(learning_rate=0.01)
model.compile(
    optimizer = opt,
    loss = 'mse',
    metrics = ['mse'],
)

```

Langkah 1. Proses *backpropagation*

Proses backpropagation dengan bantuan model.fit

```

hist = model.fit(data_training, y_train, epochs=1000, validation_split = 0.1)

```

Langkah 2. Update Bias dan Bobot

Melakukan update bobot dan bias dari *input layer* menuju *hidden layer* (vjk)

```

print("FirstLayer")
weights=data_training.iloc[0:512, :-1]
print((model.get_layer("FirstLayer").weights))

```

Melakukan update bobot dan bias dari *hidden layer* (vjk) menuju *output layer* (wjk)

```

print("LastLayer")
print((model.get_layer("LastLayer").weights))

```

Proses Prediksi

Proses prediksi dilakukan setelah diketahui bobot dan bias baru berdasarkan data testing dengan menggunakan model.predict,

```

y_pred = model.predict(data_testing)
print(y_pred)

```

3.4.4 Denormalisasi

Dalam proses denormalisasi, data yang dinormalisasi yang diskalakan dari 0 ke 1 diskalakan kembali ke skala nilai aslinya dengan menggunakan persamaan 2.17. Sebelum itu perlu menemukan nilai MIN dan MAX dari data asli. Contoh data setelah dilakukan denormalisasi dapat dilihat pada Gambar 3.6 berikut.

Nama Daerah	Suhu Rata-rata (°C)	Kelembapan Udara (%)	Ketinggian (mdpl)	Luas Lahan Hijau (ha)	Jarak dari Laut (km)	Jumlah Gunung	Ketersediaan Air (juta m ³ /thn)	Luas Wilayah (km ²)	Curah Hujan (mm/Tahun)
Kauman	0,10	0,73	0,14	0,19	0,33	0,10	0,18	0,18	0,40
Gondang	0,10	0,73	0,14	0,21	0,31	0,10	0,22	0,22	0,42
Pagerwojo	0,10	0,73	0,32	0,32	0,42	0,30	0,50	0,38	0,63
Sendang	0,10	0,73	0,32	0,39	0,41	0,10	0,62	0,41	0,74
Bakung	0,10	0,73	0,17	0,32	0,12	0,30	0,23	0,46	0,17
Wonotirto	0,10	0,73	0,28	0,59	0,17	0,30	0,40	0,64	0,26
Panggungrejo	0,10	0,73	0,24	0,49	0,17	0,10	0,45	0,48	0,41
Wates	0,10	0,73	0,29	0,33	0,16	0,30	0,22	0,31	0,26
Binangun	0,10	0,73	0,21	0,36	0,20	0,10	0,33	0,34	0,43
Sutojayan	0,10	0,73	0,17	0,20	0,27	0,10	0,25	0,23	0,49
Kademangan	0,10	0,73	0,21	0,34	0,23	0,10	0,31	0,44	0,28

(a)


Nama Daerah	Suhu Rata-rata (°C)	Kelembapan Udara (%)	Ketinggian (mdpl)	Luas Lahan Hijau (ha)	Jarak dari Laut (km)	Jumlah Gunung	Ketersediaan Air (juta m ³ /thn)	Luas Wilayah (km ²)	Curah Hujan (mm/Tahun)
Kauman	21,00	94,00	90,00	1944,00	23,94	0,00	4.440,96	30,84	144,0000
Gondang	21,00	94,00	96,00	2316,00	21,30	0,00	6735,06	44,02	153,00
Pagerwojo	21,00	94,00	476,00	4711,00	32,43	1,00	20290,60	88,22	230,00
Sendang	21,00	94,00	493,00	5993,00	31,82	0,00	26140,66	96,46	271,00
Bakung	21,00	94,00	160,00	4633,00	2,24	1,00	6785,64	111,24	61,00
Wonotirto	21,00	94,00	387,00	10304,00	7,43	1,00	15494,73	164,54	94,17
Panggungrejo	21,00	94,00	310,00	8170,00	7,72	0,00	17895,68	119,04	150,33
Wates	21,00	94,00	420,00	4860,00	6,49	1,00	6472,17	68,76	94,13
Binangun	21,00	94,00	243,00	5400,00	10,87	0,00	11883,25	76,79	154,75
Sutojayan	21,00	94,00	150,00	2038,00	17,48	0,00	7944,95	44,20	179,75
Kademangan	21,00	94,00	246,00	5081,00	13,07	0,00	10738,56	105,28	102,00

(b)

Gambar 3.6 Nilai Data Setelah Proses Denormalisasi (a) Data Normalisasi (b) Data Hasil Denormalisasi


3.5 Proses Training

Proses training data dilakukan dengan membagi data dengan proporsi 80% untuk data training dan 20% untuk data testing dari 640 data. Data untuk proses training sebanyak 512 data dengan parameter *input layer* sebanyak 8, *hidden layer* sebanyak 1 dengan jumlah neuron 2, *output layer* sebanyak 1, *learning rate* sebesar 0,01 dan 1000 epoch. Contoh proses training data curah hujan kecamatan ditunjukkan pada Gambar 3.7 berikut.



Gambar 3.7 Grafik MSE Curah Hujan Kecamatan berdasarkan 8 Faktor Penentu Curah Hujan

Proses training juga dilakukan untuk data curah hujan kabupaten/kota berdasarkan parameter rata-rata suhu dan kelembaban. Contoh proses training data curah hujan kabupaten ditunjukkan oleh Gambar 3.8 berikut.



Gambar 3.8 Grafik MSE Curah Hujan Kabupaten berdasarkan Suhu dan Kelembaban

Dapat dilihat bahwa grafik MSE pada Gambar 3.7 dan Gambar 3.8 menunjukkan bahwa nilai MSE sudah melandai menuju nilai 0,00 dan proses training sudah berhasil menuju konvergensi. Selanjutnya, model arsitektur akan digunakan dalam pengujian model.

BAB IV

UJI COBA DAN PEMBAHASAN

Bab ini akan menjelaskan dan membahas hasil implementasi algoritma *backpropagation* yang digunakan untuk memprediksi curah hujan kecamatan di Jawa Timur. Hasil pengujian berupa model jaringan saraf tiruan terbaik, disajikan dalam bentuk tabel dan grafik data, dan kesalahan akan dihitung menggunakan MAPE.

4.1 Skenario Model

Terdapat beberapa parameter yang akan diubah pada tahap ini, diantaranya:

1. Jumlah neuron dalam *hidden layer* sebanyak kurang dari dua kali jumlah neuron pada *input layer* atau $2/3$ dari jumlah neuron pada *input layer* ditambah dengan jumlah neuron pada *output layer* (Heaton, 2005) yaitu 2, 4, 6, 8, 10, 12.
2. Menurut Abdull Hamed, Shamsuddin, & Salim (2006) dalam penentuan *learning rate* tidak ada metode baku, nilai *learning rate* berada pada rentang 0 hingga 1. Kecepatan proses pelatihan dipengaruhi oleh parameter *learning rate*. Untuk dapat mencapai kondisi konvergensi, pilihan *learning rate* memiliki pengaruh yang besar. Semakin tinggi *learning rate*, semakin cepat proses pelatihan berjalan mencapai konvergensi sehingga menyebabkan akurasi jaringan semakin rendah, sebaliknya semakin rendah *learning rate* maka semakin lama proses pelatihan sehingga menyebabkan akurasi jaringan semakin tinggi. Pada penelitian ini menggunakan *Learning rate* sebesar 0,01;0,02;0,04;0,06;0,08;0,10;0,14;0,18;0,20.

Hasil dari uji coba tersebut akan menghasilkan beberapa arsitektur jaringan saraf tiruan untuk prediksi curah hujan kecamatan dan prediksi curah hujan kabupaten di Jawa Timur. Berdasarkan arsitektur tersebut maka akan dipilih arsitektur mana yang menghasilkan nilai MAPE terkecil.

Pengujian dirancang untuk menemukan model terbaik untuk memprediksi curah hujan. Pengujian dengan JST *backpropagation* dilakukan dengan memberikan batas *epoch* untuk setiap proses pelatihan, jumlah *epoch* ditentukan sebesar 1000 *epoch*. Efek pembelajaran yaitu membentuk arsitektur jaringan dengan mengubah jumlah neuron pada lapisan tersembunyi dan nilai *learning rate* pada kisaran 0,01-0,20. Proses pengujian ini akan menggunakan 54 model yang berbeda. Model pertama dengan 8 *input* dan Model kedua dengan 2 *input*.

4.2 Hasil Pengujian Model

4.2.1 Pengujian Model Pertama

Pengujian Model Pertama menggunakan 8 *input* berdasarkan 8 faktor penentu curah hujan yaitu suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut, ketersediaan air berdasarkan kecamatan. Hasil pengujian menghasilkan persentase error setiap model, ditunjukkan pada Tabel 4.1.

Tabel 4.1 Hasil Pengujian Model Pertama ANN

No	Nama Model	Arsitektur				Persentase Error
		<i>Input</i>	Neuron <i>Hidden</i>	<i>Output</i>	Lr	
1	Model A	8	2	1	0,01	35,31%
2	Model B	8	4	1	0,01	29,33%
3	Model C	8	6	1	0,01	26,55%

Lanjutan Tabel 4.1

No	Nama Model	Arsitektur				Persentase Error
		<i>Input</i>	Neuron <i>Hidden</i>	<i>Output</i>	Lr	
4	Model D	8	8	1	0,01	29,66%
5	Model E	8	10	1	0,01	27,48%
6	Model F	8	12	1	0,01	28,09%
7	Model G	8	2	1	0,02	27,44%
8	Model H	8	4	1	0,02	25,59%
9	Model I	8	6	1	0,02	26,09%
10	Model J	8	8	1	0,02	26,52%
11	Model K	8	10	1	0,02	26,95%
12	Model L	8	12	1	0,02	25,47%
13	Model M	8	2	1	0,04	24,02%
14	Model N	8	4	1	0,04	22,34%
15	Model O	8	6	1	0,04	21,53%
16	Model P	8	8	1	0,04	25,84%
17	Model Q	8	10	1	0,04	25,91%
18	Model R	8	12	1	0,04	22,69%
19	Model S	8	2	1	0,06	23,37%
20	Model T	8	4	1	0,06	22,70%
21	Model U	8	6	1	0,06	20,86%
22	Model V	8	8	1	0,06	22,14%
23	Model W	8	10	1	0,06	20,91%
24	Model X	8	12	1	0,06	20,46%
25	Model Y	8	2	1	0,08	21,38%
26	Model Z	8	4	1	0,08	24,32%
27	Model AA	8	6	1	0,08	17,52%
28	Model AB	8	8	1	0,08	17,78%
29	Model AC	8	10	1	0,08	15,40%
30	Model AD	8	12	1	0,08	22,37%
31	Model AE	8	2	1	0,10	23,19%
32	Model AF	8	4	1	0,10	22,23%
33	Model AG	8	6	1	0,10	19,56%
34	Model AH	8	8	1	0,10	16,26%

Lanjutan Tabel 4.1

No	Nama Model	Arsitektur				Persentase Error
		<i>Input</i>	Neuron <i>Hidden</i>	<i>Output</i>	Lr	
35	Model AI	8	10	1	0,10	17,59%
36	Model AJ	8	12	1	0,10	18,48%
37	Model AK	8	2	1	0,14	18,12%
38	Model AL	8	4	1	0,14	26,03%
39	Model AM	8	6	1	0,14	18,44%
40	Model AN	8	8	1	0,14	16,33%
41	Model AO	8	10	1	0,14	17,35%
42	Model AP	8	12	1	0,14	18,97%
43	Model AQ	8	2	1	0,18	23,13%
44	Model AR	8	4	1	0,18	12,82%
45	Model AS	8	6	1	0,18	17,32%
46	Model AT	8	8	1	0,18	16,29%
47	Model AU	8	10	1	0,18	18,38%
48	Model AV	8	12	1	0,18	20,47%
49	Model AW	8	2	1	0,20	18,28%
50	Model AX	8	4	1	0,20	18,34%
51	Model AY	8	6	1	0,20	16,15%
52	Model AZ	8	8	1	0,20	22,64%
53	Model BA	8	10	1	0,20	18,07%
54	Model BB	8	12	1	0,20	13,70%

4.2.2 Pengujian Model Kedua

Pengujian Model Kedua dengan menggunakan 2 *input* berdasarkan 2 faktor penentu curah hujan yaitu suhu dan kelembaban berdasarkan kabupaten. Hasil pengujian menghasilkan persentase error setiap model, ditunjukkan pada Tabel 4.2

Tabel 4.2 Hasil Pengujian Model Kedua ANN

No	Nama Model	Arsitektur				Persentase Error
		<i>Input</i>	Neuron <i>Hidden</i>	<i>Output</i>	Lr	
1	Model 1	2	2	1	0,01	48,91%
2	Model 2	2	4	1	0,01	59,81%
3	Model 3	2	6	1	0,01	58,39%
4	Model 4	2	8	1	0,01	49,66%
5	Model 5	2	10	1	0,01	49,33%
6	Model 6	2	12	1	0,01	49,33%
7	Model 7	2	2	1	0,02	57,02%
8	Model 8	2	4	1	0,02	59,09%
9	Model 9	2	6	1	0,02	49,42%
10	Model 10	2	8	1	0,02	55,22%
11	Model 11	2	10	1	0,02	55,65%
12	Model 12	2	12	1	0,02	57,62%
13	Model 13	2	2	1	0,04	56,17%
14	Model 14	2	4	1	0,04	53,81%
15	Model 15	2	6	1	0,04	58,22%
16	Model 16	2	8	1	0,04	52,90%
17	Model 17	2	10	1	0,04	54,23%
18	Model 18	2	12	1	0,04	58,73%
19	Model 19	2	2	1	0,06	55,86%
20	Model 20	2	4	1	0,06	56,60%
21	Model 21	2	6	1	0,06	53,20%
22	Model 22	2	8	1	0,06	57,12%
23	Model 23	2	10	1	0,06	56,72%
24	Model 24	2	12	1	0,06	54,77%
25	Model 25	2	2	1	0,08	54,57%
26	Model 26	2	4	1	0,08	53,16%
27	Model 27	2	6	1	0,08	55,62%
28	Model 28	2	8	1	0,08	53,05%
29	Model 29	2	10	1	0,08	48,64%
30	Model 30	2	12	1	0,08	52,87%
31	Model 31	2	2	1	0,10	54,65%

Lanjutan Tabel 4.2

No	Nama Model	Arsitektur				Persentase Error
		<i>Input</i>	Neuron <i>Hidden</i>	<i>Output</i>	Lr	
32	Model 32	2	4	1	0,10	55,34%
33	Model 33	2	6	1	0,10	56,12%
34	Model 34	2	8	1	0,10	54,56%
35	Model 35	2	10	1	0,10	52,81%
36	Model 36	2	12	1	0,10	54,61%
37	Model 37	2	2	1	0,14	50,38%
38	Model 38	2	4	1	0,14	52,79%
39	Model 39	2	6	1	0,14	53,12%
40	Model 40	2	8	1	0,14	54,93%
41	Model 41	2	10	1	0,14	55,92%
42	Model 42	2	12	1	0,14	56,98%
43	Model 43	2	2	1	0,18	53,28%
44	Model 44	2	4	1	0,18	55,67%
45	Model 45	2	6	1	0,18	55,19%
46	Model 46	2	8	1	0,18	53,39%
47	Model 47	2	10	1	0,18	55,47%
48	Model 48	2	12	1	0,18	53,37%
49	Model 49	2	2	1	0,20	51,93%
50	Model 50	2	4	1	0,20	55,21%
51	Model 51	2	6	1	0,20	53,21%
52	Model 52	2	8	1	0,20	53,80%
53	Model 53	2	10	1	0,20	53,80%
54	Model 54	2	12	1	0,20	54,60%

4.3 Pembahasan Pengujian Model

Hasil pengujian 54 Model Pertama dan 54 Model Kedua menunjukkan bahwa kedua model memiliki perbedaan nilai MAPE dengan *range* yang berbeda. Pada prediksi curah hujan kecamatan dengan berdasarkan 8 faktor penentu curah hujan dengan neuron pada *input layer* sebesar 8 memiliki nilai MAPE yang relatif

lebih kecil dikarenakan memiliki lebih banyak neuron *input* dibandingkan prediksi curah hujan berdasarkan 2 faktor penentu curah hujan. Semakin banyak jumlah neuron *input* yang digunakan maka prediksi dapat bekerja lebih baik dalam mengenali pola (Olivya, Tungadi, & Rante 2018). Terdapat nilai yang sama pada data faktor suhu dan data faktor kelembaban, namun masih terdapat 6 faktor lain yang nilainya berbeda sehingga menyebabkan sistem dapat memprediksi lebih baik. Sedangkan pada prediksi curah hujan kabupaten dengan berdasarkan suhu dan kelembaban memiliki rata-rata nilai MAPE yang lebih besar dikarenakan jumlah neuron *input* yang sedikit. Selain itu, terdapat data suhu dan data kelembaban yang sama dengan output yang berbeda yang membuat sistem buruk dalam memodelkan pola sehingga menyebabkan hasil prediksi kurang baik.

Pengujian pada 54 Model Pertama didapatkan 3 model terbaik berdasarkan nilai MAPE yaitu Model AC, Model AR dan Model BB. Ketiga model tersebut kemudian dilakukan perulangan sebanyak 5 kali untuk melihat seberapa konsisten model tersebut.

Tabel 4.3 Hasil Pengujian Model AC dengan Standar Deviasi

Perulangan ke-	MAPE
1	20,95%
2	19,83%
3	19,50%
4	14,65%
5	15,91%
Rata-rata	18,17%
Standar Deviasi	2,72

Model AC pada Tabel 4.3 dengan arsitektur 8-10-1 dengan learning rate 0,08 menunjukkan hasil rata-rata MAPE sebesar 18,17% dan standar deviasi sebesar 2,72.

Tabel 4.4 Hasil pengujian Model AR dengan Standar Deviasi

Perulangan ke-	MAPE
1	17,90%
2	15,70%
3	16,01%
4	13,17%
5	16,24%
Rata-rata	15,81%
Standar Deviasi	1,70

Model AR pada Tabel 4.4 dengan arsitektur 8-4-1 dengan learning rate 0,18 menunjukkan hasil rata-rata MAPE sebesar 15,81% dan standar deviasi sebesar 1,70.

Tabel 4.5 Hasil pengujian Model BB dengan Standar Deviasi

Perulangan ke-	MAPE
1	17,00%
2	15,06%
3	15,75%
4	19,23%
5	19,99%
Rata-rata	17,41%
Standar Deviasi	2,14

Model BB pada Tabel 4.5 dengan arsitektur 8-12-1 dengan learning rate 0,20 menunjukkan hasil rata-rata MAPE sebesar 17,41% dan standar deviasi sebesar 2,14.

Model terbaik ditemukan berdasarkan nilai MAPE yaitu Model AR dengan arsitektur 8-4-1 yang memiliki 8 neuron *input* berdasarkan 8 faktor penentu curah

hujan. Faktor-faktor tersebut diantaranya: suhu, kelembaban, ketinggian, luas wilayah, jumlah gunung, luas lahan hijau, jarak dari laut dan ketersediaan air sebagai variabel masukkan. Jumlah neuron *input* yang berjumlah 8 berpengaruh pada hasil prediksi, jika terlalu kecil jaringan tidak akan dapat memproses informasi yang masuk dengan benar dan kemungkinan besar akan membuat keputusan yang salah. Sebaliknya, jika jumlah *input* neuron terlalu banyak, jaringan menjadi terlalu kompleks dan proses pembelajaran akan memakan waktu lebih lama.

Hidden layer akan bekerja dengan optimal apabila menggunakan 1 *hidden layer* dengan jumlah neuron 4. Jika jumlah neuron *hidden layer* lebih besar dari jumlah neuron *input* akan menghasilkan hasil yang lebih akurat, namun membutuhkan waktu yang lebih lama untuk melakukan proses pembelajaran sehingga menghasilkan hasil prediksi yang kurang efisien dari segi waktu dan sumber daya. *Output layer* terdiri dari 1 neuron berupa curah hujan dan *Learning rate* akan bekerja secara optimal pada nilai 0,18.

Rata-rata MAPE yang dihasilkan sebesar 15,81% menunjukkan bahwa selisih antara nilai prediksi dan nilai sebenarnya sangat kecil. Semakin kecil nilai MAPE, semakin dekat nilai yang diperkirakan oleh model dengan nilai aktual, sehingga model prediksi menggunakan 8 *input* berdasarkan 8 variabel memiliki tingkat akurasi yang baik. Selain itu juga menghasilkan standar deviasi sebesar 1,70 membuktikan bahwa semakin kecil standar deviasi, semakin stabil hasil yang dihasilkan oleh model.

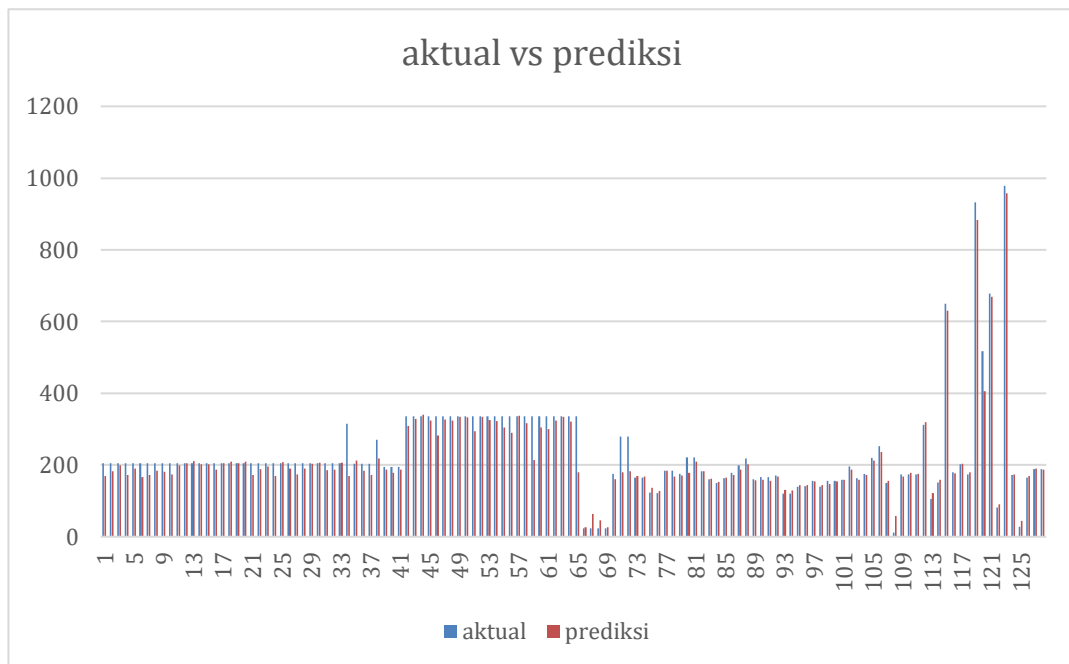
Model AR kemudian dilakukan denormalisasi untuk mengembalikan nilai hasil prediksi kedalam bentuk nilai aslinya. Selain itu, dari denormalisasi data dapat

diketahui curah hujan pada kecamatan di Jawa Timur berdasarkan data faktor-faktor penentu curah hujan seperti yang ditunjukkan pada Tabel 4.6 berikut.

Tabel 4.6 Denormalisasi Model AR

Nama Daerah	Normalisasi Prediksi	Denormalisasi Prediksi	Data Aktual
Ampelgading	0,24	169,56	204,75
Bantur	0,25	182,92	204,75
Bululawang	0,26	198,68	204,75
Dampit	0,24	172,58	204,75
Dau	0,25	169,56	204,75
Donomulyo	0,27	165,58	204,75
Gedangan	0,27	172,15	204,75
Gondanglegi	0,27	184,28	204,75
Jabung	0,27	181,14	204,75
Kalipare	0,27	173,20	204,75
Karangploso	0,27	198,36	204,75
Kepanjen	0,27	205,54	204,75
Kromengan	0,27	210,38	204,75
Lawang	0,27	201,60	204,75
Ngajum	0,27	201,81	204,75
Ngantang	0,27	187,39	204,75
Pagak	0,27	205,29	204,75
Pagelaran	0,27	210,06	204,75
...
Sanankulon	0,24	173,91	172,75
Ponggok	0,12	44,87	28,17
Srengat	0,24	168,82	165,17
Wonodadi	0,26	190,40	189,25
Udanawu	0,25	186,99	189,25

Model tersebut diimplementasikan menunjukkan hasil perbandingan antara data aktual yang ditunjukkan oleh grafik berwarna biru dengan data prediksi yang ditunjukkan oleh grafik berwarna jingga, dapat dilihat pada Gambar 4.1 berikut.



Gambar 4.1 Grafik perbandingan data aktual dan prediksi

Dalam penelitian ini dapat diketahui prediksi curah hujan disuatu kecamatan. Dari hasil tersebut diharapkan dapat dilakukan antisipasi terjadinya bencana yang disebabkan tinggi rendahnya curah hujan. Menurut Al-Quran turunnya air hujan secara bertahap dan teratur menurut ukuran semua makhluk di bumi atas Kuasa-Nya. Hujan turun tidak lebih dari yang dibutuhkan mahluk sehingga tidak melimpah ruah melampaui batas, tidak juga terlalu sedikit sehingga kebutuhan makhluknya tidak dapat tercukupi (Sunarsa, 2018). Sesuai dengan Q.S Az Zukhruf ayat 11, Allah berfirman:

وَالَّذِي نَزَّلَ مِنَ السَّمَاءِ مَاءً بِقَدَرٍ فَأَنْشَرْنَا بِهِ بَلْدَةً مَيْتًا ۚ كَذَلِكَ نُخْرِجُونَ

“Dan yang menurunkan air dari langit menurut kadar (yang diperlukan) lalu kami hidupkan dengan air itu negeri yang mati, seperti itulah kamu akan dikeluarkan (dari dalam kubur).”(Q.S Az Zukhruf :11)

Hujan bisa menjadi berkah, namun apabila turun secara terus menerus akan menjadi bencana. Pada tumbuhan yang kebanyakan mendapatkan asupan air maka

akan tumbuh membesar bahkan menimbulkan spesies baru. Hujan yang turun dengan volume yang terlalu banyak akan menyebabkan banjir hingga tanah longsor.

Peranan air hujan sangat penting karena air yang dihasilkan oleh air hujan adalah air tawar. Kehidupan di bumi membutuhkan air ini untuk menopang manusia, hewan, dan tumbuhan. Air ini disediakan oleh Allah untuk minum, menumbuhkan tanaman, menyuburkan tanah yang kering menjadi subur sehingga menjadi sumber pangan bagi hewan dan manusia melalui tumbuh-tumbuhan dan buah-buahan yang dihasilkan. Selain itu, air juga digunakan untuk bersuci baik untuk wudhu maupun untuk mandi (Santoso, 2014). Allah berfirman dalam Q.S An-Nahl ayat 10 :

هُوَ الَّذِي أَنْزَلَ مِنَ السَّمَاءِ مَاءً لَكُمْ مِنْهُ شَرَابٌ وَمِنْهُ شَجَرٌ فِيهِ تُسِيمُونَ

“Dialah yang telah menurunkan air (hujan) dari langit untuk kamu, sebagiannya menjadi minuman dan sebagiannya (menyuburkan) tumbuhan, padanya kamu menggembalakan ternakmu.”(Q.S An-Nahl:10)

Menurut Tafsir Ibnu Katsir, ayat ini menerangkan bahwa Dialah Allah yang telah menurunkan air hujan dari langit untuk kalian, sebagiannya menjadi minuman dan sebagiannya tumbuh-tumbuhan, yang pada kalian menggembalakan ternak kalian. Artinya, air hujan itu dijadikan oleh Allah memiliki rasa tawar agar dapat diminum oleh kalian, dan Allah tidak menjadikannya berasa asin lagi pahit. Dengan kata lain, dari pengaruh air hujan itu Allah menjadikan tumbuh-tumbuhan sehingga dapat kalian jadikan sebagai tempat untuk menggembalakan ternak kalian (Al-Sheikh, 2003).

BAB V

PENUTUP

Bab ini akan menjelaskan kesimpulan dari penelitian yang telah dilakukan pada bab sebelumnya tentang implementasi algoritma *Artificial Neural Network Backpropagation* untuk memprediksi curah hujan kecamatan di Jawa Timur berdasarkan faktor-faktor penentu curah hujan. Saran yang disampaikan peneliti ketika menggunakan penelitian ini diharapkan dapat menjadi referensi sehingga menghasilkan penelitian yang lebih baik di masa mendatang.

5.1 Kesimpulan

Model jaringan saraf tiruan terbaik adalah model pertama dengan jumlah *input* sebanyak 8 berdasarkan 8 faktor penentu curah hujan, yaitu model AR dengan arsitektur 8-4-1 dan *learning rate* sebesar 0,18 untuk memprediksi curah hujan kecamatan di Jawa Timur menghasilkan rata-rata MAPE sebesar 14,52% dan standar deviasi sebesar 2,10%. Nilai MAPE menunjukkan <20% maka hasil prediksi dalam kategori baik.

5.2 Saran

Saran yang dapat penulis sampaikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Pada penelitian ini dilakukan prediksi curah hujan berdasarkan 8 faktor penentu

curah hujan, penelitian selanjutnya diharapkan dapat dilakukan prediksi sekaligus mengetahui faktor mana yang sangat berpengaruh dalam tinggi rendahnya curah hujan.

2. Faktor penentu tinggi rendahnya curah hujan terdapat 8, pada penelitian selanjutnya diharapkan menambahkan faktor yang lain.
3. Metode yang digunakan dalam penelitian ini adalah *Backpropagation Neural Network*, penelitian selanjutnya dapat menggunakan metode lain seperti Regresi Linier, KNN, CNN dll.

DAFTAR PUSTAKA

- Abdull Hamed, H. N., Shamsuddin, S. M., & Salim, N. (2006). Particle Swarm Optimization For Neural Network Learning Enhancement. *Thesis*, 49(1). <https://doi.org/10.11113/jt.v49.194>
- Aini, N. (2021). 9 Faktor yang Mempengaruhi Curah Hujan di Indonesia Beserta Penjelasan. Retrieved June 5, 2022, from <https://haloedukasi.com/faktor-yang-mempengaruhi-curah-hujan-di-indonesia>
- Al-Sheikh, D. A. bin M. bin A. bin I. (2003). *Tafsir Ibnu Katsir Jilid 5*. (D. Hartono & A. Rajab, Eds.) (1st ed.). Bogor: Pustaka Imam asy-Syafi'i.
- Amrizal, V., & Aini, Q. (2013). *Kecerdasan Buatan*. Jakarta: Halaman Moeka Publishing.
- Andrian, Y., & Ningsih, E. (2014). Prediksi Curah Hujan Di Kota Medan Menggunakan Metode Backpropagation Neural Network. *Seminar Nasional Informatika*, 184–189.
- Anwar, M. R., Liu, D. L., Farquharson, R., Macadam, I., Abadi, A., Finlayson, J., ... Ramilan, T. (2015). Climate change impacts on phenology and yields of five broadacre crops at four climatologically distinct locations in Australia. *Agricultural Systems*, 132, 133–144. <https://doi.org/10.1016/j.agsy.2014.09.010>
- Aprianto, R., & Puspitasari, P. A. D. (2020). Prediksi Curah Hujan Bulanan Tahun 2020 Kabupaten Sumbawa Menggunakan Artificial Neural Network (ANN) Back Propagation. *Prosiding Seminar Nasional IPPeMas*, 1(1), 622–628.
- Ardana, P. D. H., Sudika, I. G. M., Astariani, N. K., & Sumarda, G. (2019). Application of feed forward backpropagation neural network in monthly rainfall prediction. *International Journal of Advanced Trends in Computer Science and Engineering*, 8(1.5 Special Issue), 192–198. <https://doi.org/10.30534/ijatcse/2019/3681.52019>
- Badwi, N., Maru, R., & Abbas, I. (2017). Analisis Spasial Tingkat Kekeringan Sebagai Upaya Mitigasi Kegagalan Panen Di Kabupaten Takalar Sulawesi Selatan. *Indonesian Journal of Fundamental Sciences*, 3(2), 116. <https://doi.org/10.26858/ijfs.v3i2.4782>
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- BMKG. (2008). *Curah Hujan dan Potensi Bencana Gerakan Tanah*.

- BMKG. (2010). *Kondisi Cuaca Ekstrem dan Iklim Tahun 2010-2011*. Jakarta.
- Duarte, F. (2021). Perubahan iklim: Kebakaran hutan, gelombang panas, banjir bandang - mengapa rekor cuaca terpecahkan? *BBC News*. Retrieved from <https://www.bbc.com/indonesia/majalah-58007395>
- Fadhilah, R. N., & Ginardi, R. V. H. (2017). Penentuan Harga Dengan Metode Back Propagation pada Aplikasi E-Commerce CariKos Berbasis Web. *Jurnal Teknik ITS*, 6(2). <https://doi.org/10.12962/j23373539.v6i2.23978>
- Fatma, D. (2018). 7 Faktor yang Mempengaruhi Curah Hujan. Retrieved June 5, 2022, from <https://ilmugeografi.com/ilmu-bumi/meteorologi/faktor-yang-mempengaruhi-curah-hujan>
- Fausset, L. V. (1994). *Fundamentals of Neural Network : Architecture, algorithm, and Application*. *IEEE Transactions on Computers*. <https://doi.org/10.1109/T-C.1969.222718>
- Gershenson, C. (2009). Artificial Neural Networks for Beginners. *ICES Journal of Marine Science*, 66(6), 1119–1129. <https://doi.org/10.1093/icesjms/fsp009>
- Hamdani, A. F., & Susanti, N. E. (2017). Analisis Kajian Meteorologis Ketersediaan Dan Tingkat Kekritisan Air Domestik Desa Girimoyo, Kecamatan Karangploso, Kabupaten Malang. *Seminar Nasional Hasil Penelitian Universitas Kanjuruhan Malang*, 5, 5–24.
- Han, J., & Kamber, M. (2006). *Data mining: Concepts and Techniques. Proceedings - 2013 International Conference on Machine Intelligence Research and Advancement, ICMIRA 2013*. <https://doi.org/10.1109/ICMIRA.2013.45>
- Handayani, L., & Adri, M. (2015). Penerapan JST (Backpropagation) untuk Prediksi Curah Hujan (Studi Kasus : Kota Pekanbaru). *Seminar Nasional Teknologi Informasi, Komunikasi Dan Industri (SNTIKI) 7*, (November), 238–247.
- Haykin, S. (2009). *Neural Networks And Learning Machines* (3rd ed.). United State of America: Pearson.
- Heaton, J. (2005). *Introduction to Neural Networks with Java*. (M. McKinnis, Ed.) (Vol. 99). United State of America: Heaton Research, Inc.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2012). *An Introduction to Statistical Learning with Application in R*. *Current Medicinal Chemistry* (Vol. 7). <https://doi.org/10.2174/0929867003374372>

- Jay Heizer, Render, B., & Munson, C. (2017). *Operations Management Sustainability and Supply Chain Management* (12th ed.). New Delhi: Pearson Education : Boston.
- Julpan, Nababan, E. B., & Zarlis, M. (2015). Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar Dalam Algoritma Backpropagation Pada Prediksi Kemampuan Siswa. *Jurnal Teknovasi*, 02, 103–116.
- Kusmaryanto, S. (2014). Jaringan Saraf Tiruan Backpropagation untuk Pengenalan Wajah Metode Ekstraksi Fitur Berbasis Histogram. *Jurnal EECCIS Vol. 8, No. 2, Desember 2014*, 8(2), 193–198.
- Kusumadewi, S. (2004). *Membangun Jaringan Saraf Tiruan (Menggunakan MATLAB & Excel Link)*. (F. W. Nurwiyati, Ed.) (pertama ce). Yogyakarta: Graha Ilmu.
- Lesnussa, Y. A., Mustamu, C. G., Kondo Lembang, F., & Talakua, M. W. (2018). Application of Backpropagation Neural Networks in Predicting Rainfall Data in Ambon City. *International Journal of Artificial Intelligence Research*, 2(2). <https://doi.org/10.29099/ijair.v2i2.59>
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods : a practical guide to exponential smoothing and curve fitting*. London: Boston : Butterworth Scientific.
- McKee, C., Harmanto, D., & Whitbrook, A. (2018). A conceptual framework for combining artificial neural networks with computational aeroacoustics for design development. *Proceedings of the International Conference on Industrial Engineering and Operations Management, 2018-March*, 741–747.
- Merdekawati, G. I., & Ismail. (2019). Prediksi Curah Hujan Di Jakarta Berbasis Algoritma Levenberg Marquardt. *Jurnal Ilmiah Informatika Komputer*, 24(2), 116–128. <https://doi.org/10.35760/ik.2019.v24i2.2366>
- Muflih, G. Z., Sunardi, S., & Yudhana, A. (2019). Jaringan Saraf Tiruan Backpropagation untuk Prediksi Curah Hujan di Wilayah Kabupaten Wonosobo. *MUST: Journal of Mathematics Education, Science and Technology*, 4(1), 45. <https://doi.org/10.30651/must.v4i1.2670>
- Mukid, M. A., & Sugito. (2013). Model Prediksi Curah Hujan Dengan Pendekatan Regresi Proses Gaussian, 113–122.
- Mustakim. (2011). Pendidikan Lingkungan Hidup dan Implementasinya Dalam Pendidikan Islam (Analisis Surat Al-A'raf Ayat 56-58 Tafsir Al Misbah.
- Nabillah, I., & Ranggadara, I. (2020). Mean Absolute Percentage Error untuk

Evaluasi Hasil Prediksi Komoditas Laut. *JOINS (Journal of Information System)*, 5(2), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>

Nanda, D. M., Pudjiantoro, T. H., & Sabrina, P. N. (2022). Metode K-Nearest Neighbor (KNN) Dalam Memprediksi Curah Hujan di Kota Bandung. *Seminar Nasional Teknik Elektro, Sistem Informasi, Dan Teknik Informatika*, 387–393. Retrieved from <http://ejournal.itats.ac.id/snestik/article/view/2750%0Ahttp://ejournal.itats.ac.id/snestik/article/download/2750/2316>

Narvekar, M., Fargose, P., & Mukhopadhyay, D. (2017). Weather forecasting using ANN with error backpropagation algorithm. *Advances in Intelligent Systems and Computing*, 468, 629–639. https://doi.org/10.1007/978-981-10-1675-2_62

Nguyen, H. N., Nguyen, T. A., Ly, H. B., Tran, V. Q., Nguyen, L. K., Nguyen, M. V., & Ngo, C. T. (2020). Prediction of daily and monthly rainfall using a backpropagation neural Network. *Journal of Applied Science and Engineering (Taiwan)*, 24(3), 367–379. [https://doi.org/10.6180/jase.202106_24\(3\).0012](https://doi.org/10.6180/jase.202106_24(3).0012)

Nurmahaludin. (2014). Analisis Perbandingan Metode Jaringan Saraf Tiruan dan Regresi Linear Berganda pada Prakiraan Cuaca. *Jurnal INTEKNA*, (2), 102–209. Retrieved from <https://ejurnal.poliban.ac.id/index.php/intekna/article/view/389>

Nurmila, N., Sugiharto, A., & Sarwoko, E. A. (2010). Algoritma Back Propagation Neural Network Untuk Pengenalan Pola Karakter Huruf Jawa. *Jurnal Masyarakat Informatika*, 1(1), 1–10. <https://doi.org/10.14710/jmasif.1.1>.

Olivya, M., Tungadi, E., & Rante, N. B. (2018). Klasifikasi Kualitas Biji Kopi Ekspor Menggunakan Jaringan Saraf Tiruan Backpropagation. *Jurnal Informasi Sains Dan Teknologi (INSTEK)*, 3(2), 299–308.

Priyo, S. S., Helmie, A. W., Indra, W., Nurdin, B., & K, T. W. (2016). Backpropagation dan Aplikasinya, 135–146.

Rachman, A. S., Cholissodin, I., & Fauzi, M. A. (2018). Peramalan Produksi Gula Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation Pada PG Candi Baru Sidoarjo Adi. *Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(4), 1683–1689.

Sagar, V., & Kumar, K. (2014). A symmetric key cryptographic algorithm using counter propagation network (CPN). *ACM International Conference Proceeding Series, 11-16-Nove*. <https://doi.org/10.1145/2677855.2677906>

Santoso, M. A. F. (2014). Air Dan Pemeliharaannya Dalam Perspektif Islam.

Tarjih: Jurnal Tarjih Dan Pengembangan Pemikiran Islam, 12(1), 97–113.
Retrieved from
<https://www.jurnal.tarjih.or.id/index.php/tarjih/article/view/84>

Sharaff, A., & Roy, S. R. (2018). Comparative Analysis of Temperature Prediction Using Regression Methods and Back Propagation Neural Network. *Proceedings of the 2nd International Conference on Trends in Electronics and Informatics, ICOEI 2018*, (Icoei), 739–742.
<https://doi.org/10.1109/ICOEI.2018.8553803>

Sharma, A., & Nijhawan, G. (2015). Rainfall Prediction Using Neural Network. *International Journal of Computer Science Trends and Technology (IJCST)*, 3(3).

Shihab, M. Q. (2013). *Tafsir Al-Mishbah: Pesan, Kesan, dan Keserasian Al-Qur'an Volume 13*. Jakarta: Lentera Hati.

Siregar, H. H., Pawitan, H., Boer, R., & Yahya, S. (2003). *Model Simulasi Produksi Kelapa Sawit Berdasarkan Karakteristik Kekeringan Kasus Kebun Sawit di Lampung*. Institusi Pertanian Bogot, Bogor.

Soewarno. (2015). *Seri Hidrologi Klimatologi Pengukuran dan Pengolahan Data Curah Hujan, Contoh Aplikasi Hidrologi dalam Pengelolaan Sumber Daya Air*. Yogyakarta: Graha Ilmu.

Sofian, I. M., & Y Apriani. (2017). Metode Peramalan Jaringan Saraf Tiruan Menggunakan Algoritma Backpropagatin (Studi Kasus Peramalan Curah Hujan Kota Palembang). *Jurnal Mipa*, 40(2), 87–91.

Sunardi, Anton Yudhana, G. Z. M. (2020). Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Saraf Tiruan Backpropagation. *Jurnal Sistem Informasi*, 02, 155–162.

Sunarsa, S. (2018). Isyarat Sains Tentang Air Dalam Al-Qur'an. *Jurnal Naratas*, 2(1), 9–18.

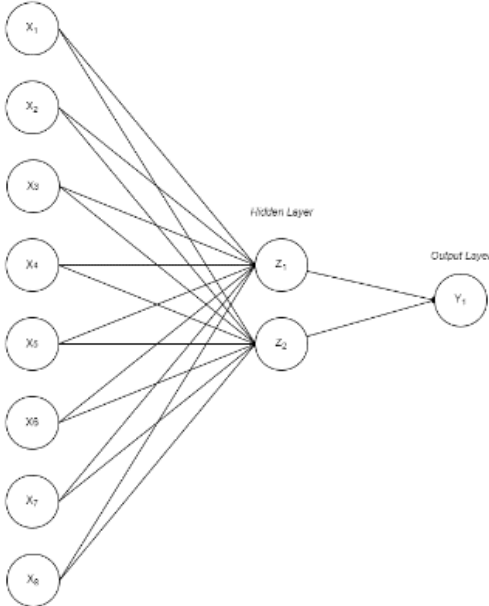
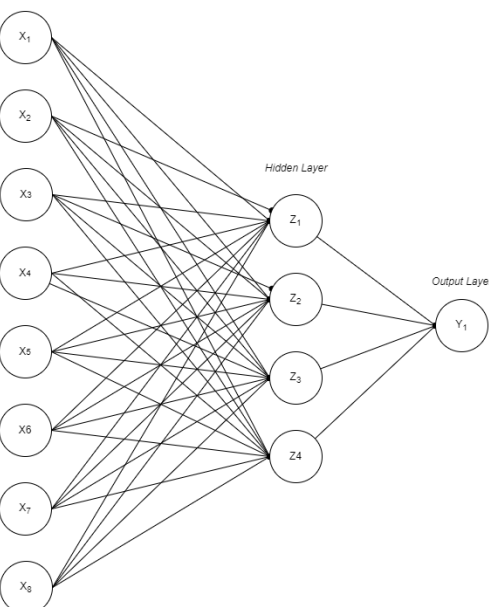
Tukidi. (2010). Karakter Curah Hujan Di Indonesia. *Jurnal Geografi*, 7(2), 136–145.
Retrieved from
<http://journal.unnes.ac.id/nju/index.php/JG/article/view/84>

Wilson, E. M. (1993). *Hidrologi Teknik* (4th ed.). Bandung: ITB PRESS.

Zubair, A. M., Tjaronge, M. W., & Ramli, M. I. (2016). Pengaruh Ketersediaan Ruang Terbuka Hijau Terhadap Iklim Mikro Di Kota Makassar. *Teknik Sipil*, 1(1), 1–12.

LAMPIRAN 1

Arsitektur Artificial Neural Network 8 Input

Arsitektur	Learning Rate	MAPE
	0,01	35,31%
	0,02	27,44%
	0,04	24,02%
	0,06	23,37%
	0,08	21,38%
	0,10	23,19%
	0,14	18,12%
	0,18	23,13%
	0,20	18,28%
	0,01	29,33%
	0,02	25,59%
	0,04	22,34%
	0,06	22,70%
	0,08	24,32%
	0,10	22,23%
	0,14	26,03%
	0,18	12,82%
	0,20	18,34%

Lanjutan lampiran 1

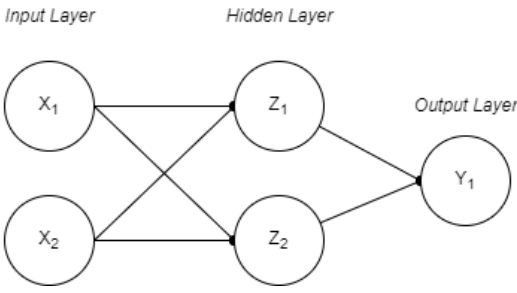
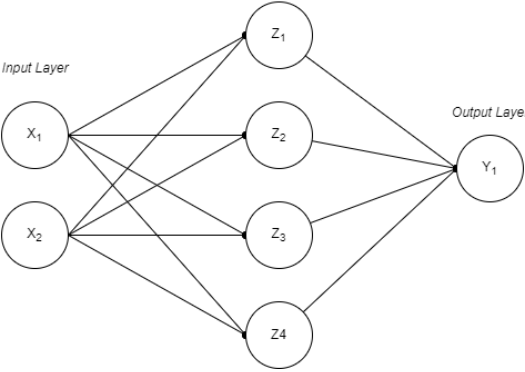
Arsitektur	Learning Rate	MAPE
<p>The diagram shows a neural network with an input layer of 8 nodes (X₁ to X₈), a hidden layer of 6 nodes (Z₁ to Z₆), and an output layer of 1 node (Y₁). All nodes in adjacent layers are fully connected.</p>	0,01	26,55%
	0,02	26,09%
	0,04	21,53%
	0,06	20,86%
	0,08	17,52%
	0,10	19,56%
	0,14	18,44%
	0,18	17,32%
0,20	16,15%	
<p>The diagram shows a neural network with an input layer of 8 nodes (X₁ to X₈), a hidden layer of 8 nodes (Z₁ to Z₈), and an output layer of 1 node (Y₁). All nodes in adjacent layers are fully connected.</p>	0,01	29,66%
	0,02	26,52%
	0,04	25,84%
	0,06	20,91%
	0,08	15,40%
	0,10	16,26%
	0,14	16,33%
	0,18	16,29%
0,20	22,64%	

Lanjutan lampiran 1

Arsitektur	Learning Rate	MAPE
<p>The diagram shows a neural network with an input layer of 8 nodes (X₁ to X₈), a hidden layer of 10 nodes (Z₁ to Z₁₀), and an output layer of 1 node (Y₁). All nodes in adjacent layers are fully connected.</p>	0,01	27,48%
	0,02	26,95%
	0,04	21,53%
	0,06	20,91%
	0,08	15,40%
	0,10	17,59%
	0,14	17,35%
	0,18	18,38%
	0,20	18,07%
<p>The diagram shows a neural network with an input layer of 8 nodes (X₁ to X₈), a hidden layer of 12 nodes (Z₁ to Z₁₂), and an output layer of 1 node (Y₁). All nodes in adjacent layers are fully connected.</p>	0,01	28,09%
	0,02	25,47%
	0,04	22,69%
	0,06	20,46%
	0,08	22,37%
	0,10	18,48%
	0,14	18,97%
	0,18	20,47%
	0,20	13,70%

LAMPIRAN 2

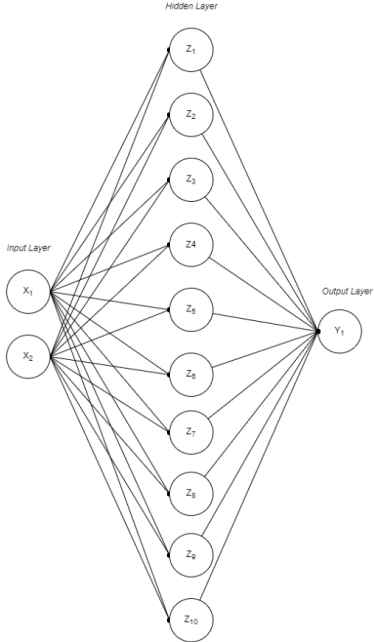
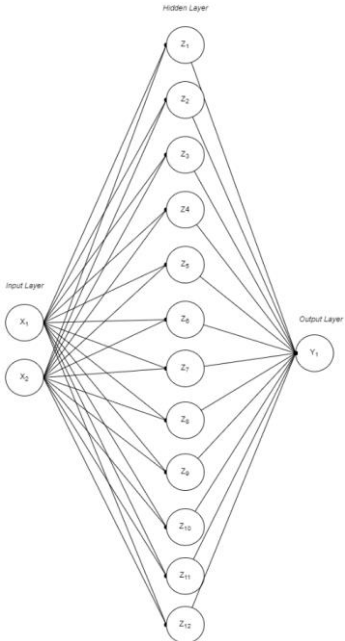
Arsitektur Artificial Neural Network 2 Input

Arsitektur	Learning Rate	MAPE
 <p data-bbox="327 638 845 929">Input Layer: X_1, X_2 Hidden Layer: Z_1, Z_2 Output Layer: Y_1</p>	0,01	48,91%
	0,02	57,02%
	0,04	56,17%
	0,06	55,86%
	0,08	54,57%
	0,10	54,65%
	0,14	50,38%
	0,18	53,28%
 <p data-bbox="319 1265 845 1635">Input Layer: X_1, X_2 Hidden Layer: Z_1, Z_2, Z_3, Z_4 Output Layer: Y_1</p>	0,01	59,81%
	0,02	59,09%
	0,04	53,81%
	0,06	56,60%
	0,08	53,16%
	0,10	55,34%
	0,14	52,79%
	0,18	55,67%
0,20	55,21%	

Lanjutan Tabel Lampiran 2

Arsitektur	Learning Rate	MAPE
<p>The diagram shows a neural network with an Input Layer containing nodes x_1 and x_2, a Hidden Layer containing nodes z_1 through z_6, and an Output Layer containing node y_1. All nodes in adjacent layers are fully connected.</p>	0,01	58,39%
	0,02	49,42%
	0,04	58,22%
	0,06	53,20%
	0,08	55,62%
	0,10	56,12%
	0,14	53,12%
	0,18	55,19%
	0,20	53,21%
<p>The diagram shows a neural network with an Input Layer containing nodes x_1 and x_2, a Hidden Layer containing nodes z_1 through z_8, and an Output Layer containing node y_1. All nodes in adjacent layers are fully connected.</p>	0,01	49,66%
	0,02	55,22%
	0,04	52,90%
	0,06	57,12%
	0,08	53,05%
	0,10	54,56%
	0,14	54,93%
	0,18	53,39%
	0,20	53,80%

Lanjutan Tabel Lampiran 2

Arsitektur	Learning Rate	MAPE
 <p>The diagram shows a neural network with an input layer containing nodes x_1 and x_2, a hidden layer containing nodes z_1 through z_{10}, and an output layer containing node y_1. All nodes in adjacent layers are fully connected.</p>	0,01	49,33%
	0,02	55,65%
	0,04	54,23%
	0,06	56,72%
	0,08	48,64%
	0,10	52,81%
	0,14	55,92%
	0,18	55,47%
	0,20	53,80%
	 <p>The diagram shows a neural network with an input layer containing nodes x_1 and x_2, a hidden layer containing nodes z_1 through z_{12}, and an output layer containing node y_1. All nodes in adjacent layers are fully connected.</p>	0,01
0,02		57,62%
0,04		58,73%
0,06		54,77%
0,08		52,87%
0,10		54,61%
0,14		56,98%
0,18		53,37%
0,20		54,60%

LAMPIRAN 3

Hasil Pengujian Model

Model A

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	268,53	31,15%		0,01
2	204,75	226,33	10,54%		
3	204,75	197,66	3,46%		
4	204,75	263,71	28,79%		
5	204,75	203,82	0,45%		
...		
128	189,25	157,60	16,72%		
MAPE			35,31%		

Model B

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	229,87	12,27%		0,01
2	204,75	245,79	20,04%		
3	204,75	202,78	0,96%		
4	204,75	224,96	9,87%		
5	204,75	229,87	12,27%		
...		
128	189,25	166,68	11,93%		
MAPE			29,33%		

Model C

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	207,78	1,48%		0,01
2	204,75	235,58	15,05%		
3	204,75	205,90	0,56%		
4	204,75	209,42	2,28%		
5	204,75	207,78	1,48%		
...		
128	189,25	174,98	7,54%		
MAPE			26,55%		

Model D

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	232,97	13,78%		0,01
2	204,75	247,81	21,03%		
3	204,75	211,39	3,24%		
4	204,75	231,34	12,99%		
5	204,75	232,97	13,78%		
...		
128	189,25	175,26	7,39%		
MAPE			29,66%		

Model E

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	200,97	1,84%		0,01
2	204,75	232,22	13,42%		
3	204,75	205,84	0,53%		
4	204,75	204,98	0,11%		
5	204,75	200,97	1,84%		
...		
128	189,25	173,29	8,43%		
MAPE			27,48%		

Model F

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	198,24	3,18%		0,01
2	204,75	230,88	12,76%		
3	204,75	202,22	1,23%		
4	204,75	201,37	1,65%		
5	204,75	198,24	3,18%		
...		
128	189,25	165,44	12,58%		
MAPE			28,09%		

Model G

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	182,27	10,98%		0,02
2	204,75	220,49	7,69%		
3	204,75	201,12	1,77%		
4	204,75	188,42	7,98%		
5	204,75	182,27	10,98%		
...		
128	189,25	177,22	6,36%		
MAPE			27,44%		

Model H

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	188,32	8,02%		0,02
2	204,75	214,04	4,54%		
3	204,75	194,95	4,79%		
4	204,75	187,03	8,65%		
5	204,75	188,32	8,02%		
...		
128	189,25	169,95	10,20%		
MAPE			25,59%		

Model I

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	185,74	9,29%		0,02
2	204,75	217,27	6,12%		
3	204,75	198,53	3,04%		
4	204,75	191,89	6,28%		
5	204,75	185,74	9,29%		
...		
128	189,25	171,59	9,33%		
MAPE			26,09%		

Model J

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	182,14	11,04%		0,02
2	204,75	215,40	5,20%		
3	204,75	202,72	0,99%		
4	204,75	190,92	6,76%		
5	204,75	182,14	11,04%		
...		
128	189,25	181,81	3,93%		
MAPE			26,52%		

Model K

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	184,44	9,92%		0,02
2	204,75	218,04	6,49%		
3	204,75	200,51	2,07%		
4	204,75	193,10	5,69%		
5	204,75	184,44	9,92%		
...		
128	189,25	174,89	7,59%		
MAPE			26,95%		

Model L

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	180,28	11,95%		0,02
2	204,75	215,52	5,26%		
3	204,75	198,00	3,30%		
4	204,75	188,89	7,74%		
5	204,75	180,28	11,95%		
...		
128	189,25	171,80	9,22%		
MAPE			25,47%		

Model M

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	172,65	15,68%		0,04
2	204,75	201,35	1,66%		
3	204,75	196,91	3,83%		
4	204,75	176,91	13,60%		
5	204,75	172,65	15,68%		
...		
128	189,25	175,76	7,13%		
MAPE			24,02%		

Model N

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	176,48	13,81%		0,04
2	204,75	199,46	2,58%		
3	204,75	194,06	5,22%		
4	204,75	180,74	11,73%		
5	204,75	176,48	13,81%		
...		
128	189,25	171,22	9,53%		
MAPE			22,34%		

Model O

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	174,58	14,73%		0,04
2	204,75	194,72	4,90%		
3	204,75	195,74	4,40%		
4	204,75	181,62	11,30%		
5	204,75	174,58	14,73%		
...		
128	189,25	175,80	7,11%		
MAPE			21,53%		

Model P

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	177,46	13,33%		0,04
2	204,75	206,77	0,99%		
3	204,75	209,65	2,39%		
4	204,75	185,15	9,57%		
5	204,75	177,46	13,33%		
...		
128	189,25	191,36	1,12%		
MAPE			25,84%		

Model Q

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	185,68	9,31%		0,04
2	204,75	211,32	3,21%		
3	204,75	207,67	1,43%		
4	204,75	191,23	6,61%		
5	204,75	185,68	9,31%		
...		
128	189,25	194,08	2,55%		
MAPE			25,91%		

Model R

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	194,85	4,84%		0,04
2	204,75	212,09	3,58%		
3	204,75	199,19	2,72%		
4	204,75	200,29	2,18%		
5	204,75	195,75	4,39%		
...		
128	189,25	174,98	7,54%		
MAPE			22,69%		

Model S

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	170,80	16,58%		0,06
2	204,75	198,02	3,29%		
3	204,75	197,38	3,60%		
4	204,75	174,99	14,53%		
5	204,75	170,80	16,58%		
...		
128	189,25	179,74	5,03%		
MAPE			23,37%		

Model T

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	167,66	18,11%		0,06
2	204,75	193,60	5,45%		
3	204,75	194,66	4,93%		
4	204,75	171,44	16,27%		
5	204,75	167,66	18,11%		
...		
128	189,25	172,31	8,95%		
MAPE			22,70%		

Model U

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	180,15	12,02%		0,06
2	204,75	204,36	0,19%		
3	204,75	208,91	2,03%		
4	204,75	187,64	8,36%		
5	204,75	180,15	12,02%		
...		
128	189,25	192,48	1,71%		
MAPE			20,86%		

Model V

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	180,06	12,06%		0,06
2	204,75	199,96	2,34%		
3	204,75	205,32	0,28%		
4	204,75	188,27	8,05%		
5	204,75	180,06	12,06%		
...		
128	189,25	186,48	1,46%		
MAPE			22,14%		

Model W

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	183,18	10,53%		0,06
2	204,75	208,59	1,88%		
3	204,75	209,02	2,09%		
4	204,75	190,75	6,84%		
5	204,75	183,18	10,53%		
...		
128	189,25	180,50	4,62%		
MAPE			20,91%		

Model X

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	178,14	13,00%		0,06
2	204,75	202,71	0,99%		
3	204,75	206,30	0,76%		
4	204,75	185,80	9,26%		
5	204,75	178,14	13,00%		
...		
128	189,25	177,61	6,15%		
MAPE			20,46%		

Model Y

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	167,11	18,38%		0,08
2	204,75	191,08	6,67%		
3	204,75	195,30	4,62%		
4	204,75	170,98	16,49%		
5	204,75	167,11	18,38%		
...		
128	189,25	174,73	7,67%		
MAPE			21,38%		

Model Z

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	170,02	16,96%		0,08
2	204,75	193,67	5,41%		
3	204,75	204,74	0,00%		
4	204,75	176,49	13,80%		
5	204,75	170,02	16,96%		
...		
128	189,25	196,18	3,66%		
MAPE			24,32%		

Model AA

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	174,89	14,59%		0,08
2	204,75	196,85	3,86%		
3	204,75	202,51	1,10%		
4	204,75	184,91	9,69%		
5	204,75	174,89	14,59%		
...		
128	189,25	185,59	1,94%		
MAPE			17,52%		

Model AB

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	183,50	10,38%		0,08
2	204,75	194,68	4,92%		
3	204,75	200,76	1,95%		
4	204,75	191,34	6,55%		
5	204,75	183,50	10,38%		
...		
128	189,25	183,88	2,84%		
MAPE			17,78%		

Model AC

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	177,95	13,09%		0,08
2	204,75	201,75	1,47%		
3	204,75	205,82	0,52%		
4	204,75	181,35	11,43%		
5	204,75	177,95	13,09%		
...		
128	189,25	185,21	2,13%		
MAPE			15,40%		

Model AD

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	175,20	14,43%		0,08
2	204,75	203,68	0,52%		
3	204,75	210,25	2,69%		
4	204,75	182,64	10,80%		
5	204,75	175,20	14,43%		
...		
128	189,25	185,21	2,14%		
MAPE			22,37%		

Model AE

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	171,98	16,01%		0,10
2	204,75	196,40	4,08%		
3	204,75	208,61	1,89%		
4	204,75	171,98	16,01%		
5	204,75	171,98	16,01%		
...		
128	189,25	196,40	3,78%		
MAPE			23,19%		

Model AF

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	171,98	16,01%		0,10
2	204,75	184,19	10,04%		
3	204,75	208,61	1,89%		
4	204,75	171,98	16,01%		
5	204,75	171,98	16,01%		
...		
128	189,25	196,40	3,78%		
MAPE			22,23%		

Model AG

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	159,76	21,97%		0,10
2	204,75	184,19	10,04%		
3	204,75	184,19	10,04%		
4	204,75	171,98	16,01%		
5	204,75	159,76	21,97%		
...		
128	189,25	159,76	15,58%		
MAPE			19,56%		

Model AH

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	171,98	16,01%		0,10
2	204,75	196,40	4,08%		
3	204,75	196,40	4,08%		
4	204,75	184,19	10,04%		
5	204,75	171,98	16,01%		
...		
128	189,25	159,76	15,58%		
MAPE			16,26%		

Model AI

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	184,19	10,04%		0,10
2	204,75	196,40	4,08%		
3	204,75	196,40	4,08%		
4	204,75	184,19	10,04%		
5	204,75	184,19	10,04%		
...		
128	189,25	184,19	2,68%		
MAPE			17,59%		

Model AJ

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	184,19	10,04%		0,10
2	204,75	208,61	1,89%		
3	204,75	220,83	7,85%		
4	204,75	196,40	4,08%		
5	204,75	184,19	10,04%		
...		
128	189,25	196,40	3,78%		
MAPE			18,48%		

Model AK

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	156,48	23,57%		0,14
2	204,75	178,29	12,92%		
3	204,75	192,79	5,84%		
4	204,75	160,28	21,72%		
5	204,75	156,48	23,57%		
...		
128	189,25	171,20	9,54%		
MAPE			18,12%		

Model AL

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	181,63	11,29%		0,14
2	204,75	200,36	2,14%		
3	204,75	214,92	4,97%		
4	204,75	184,70	9,79%		
5	204,75	181,63	11,29%		
...		
128	189,25	203,52	7,54%		
MAPE			26,03%		

Model AM

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	170,16	16,90%		0,14
2	204,75	184,46	9,91%		
3	204,75	197,55	3,52%		
4	204,75	173,48	15,27%		
5	204,75	170,16	16,90%		
...		
128	189,25	184,45	2,54%		
MAPE			18,44%		

Model AN

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	164,99	19,42%		0,14
2	204,75	180,59	11,80%		
3	204,75	192,62	5,92%		
4	204,75	168,88	17,52%		
5	204,75	164,99	19,42%		
...		
128	189,25	165,66	12,47%		
MAPE			16,33%		

Model AO

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	177,33	13,39%		0,14
2	204,75	194,38	5,06%		
3	204,75	202,85	0,93%		
4	204,75	180,13	12,02%		
5	204,75	177,33	13,39%		
...		
128	189,25	186,05	1,69%		
MAPE			17,35%		

Model AP

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	158,16	22,75%		0,14
2	204,75	175,52	14,27%		
3	204,75	190,27	7,07%		
4	204,75	163,06	20,36%		
5	204,75	158,16	22,75%		
...		
128	189,25	166,19	12,18%		
MAPE			18,97%		

Model AQ

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	172,18	15,91%		0,18
2	204,75	192,45	6,01%		
3	204,75	213,70	4,37%		
4	204,75	175,26	14,40%		
5	204,75	172,18	15,91%		
...		
128	189,25	203,92	7,75%		
MAPE			23,13%		

Model AR

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	169,56	17,19%		0,18
2	204,75	182,92	10,66%		
3	204,75	198,68	2,97%		
4	204,75	172,58	15,71%		
5	204,75	169,56	17,19%		
...		
128	189,25	186,99	1,20%		
MAPE			12,82%		

Model AS

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	178,85	12,65%		0,18
2	204,75	191,92	6,26%		
3	204,75	204,50	0,12%		
4	204,75	181,13	11,53%		
5	204,75	195,71	4,42%		
...		
128	189,25	191,15	1,00%		
MAPE			17,32%		

Model AT

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	163,30	20,25%		0,18
2	204,75	177,69	13,22%		
3	204,75	194,15	5,18%		
4	204,75	166,28	18,79%		
5	204,75	163,30	20,25%		
...		
128	189,25	181,06	4,33%		
MAPE			16,29%		

Model AU

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	182,98	10,63%		0,18
2	204,75	201,01	1,83%		
3	204,75	220,33	7,61%		
4	204,75	188,06	8,15%		
5	204,75	182,98	10,63%		
...		
128	189,25	201,25	6,34%		
MAPE			18,38%		

Model AV

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	151,07	26,22%		0,18
2	204,75	167,24	18,32%		
3	204,75	181,36	11,42%		
4	204,75	155,58	24,01%		
5	204,75	151,07	26,22%		
...		
128	189,25	167,79	11,34%		
MAPE			20,47%		

Model AW

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	159,76	21,97%		0,20
2	204,75	184,19	10,04%		
3	204,75	196,40	4,08%		
4	204,75	159,76	21,97%		
5	204,75	159,76	21,97%		
...		
128	189,25	184,19	2,68%		
MAPE			18,28%		

Model AX

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	171,98	16,01%		0,20
2	204,75	184,19	10,04%		
3	204,75	208,61	1,89%		
4	204,75	171,98	16,01%		
5	204,75	171,98	16,01%		
...		
128	189,25	196,40	3,78%		
MAPE			18,34%		

Model AY

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	159,76	21,97%		0,20
2	204,75	171,98	16,01%		
3	204,75	184,19	10,04%		
4	204,75	171,98	16,01%		
5	204,75	159,76	21,97%		
...		
128	189,25	184,19	2,68%		
MAPE			16,15%		

Model AZ

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	147,55	27,94%		0,20
2	204,75	159,76	21,97%		
3	204,75	184,19	10,04%		
4	204,75	147,55	27,94%		
5	204,75	147,55	27,94%		
...		
128	189,25	171,98	9,13%		
MAPE			22,64%		

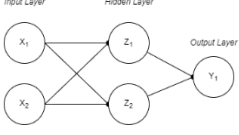
Model BA

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	159,76	21,97%		0,20
2	204,75	171,98	16,01%		
3	204,75	196,40	4,08%		
4	204,75	159,76	21,97%		
5	204,75	159,76	21,97%		
...		
128	189,25	196,40	3,78%		
MAPE			18,07%		

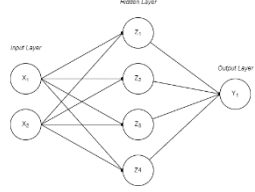
Model BB

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	204,75	171,98	16,01%		0,20
2	204,75	184,19	10,04%		
3	204,75	196,40	4,08%		
4	204,75	171,98	16,01%		
5	204,75	171,98	16,01%		
...		
128	189,25	184,19	2,68%		
MAPE			13,70%		

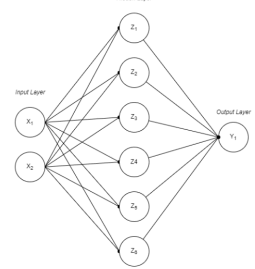
Model 1

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	153,39	15,11%		0,01
2	72,36	152,34	110,53%		
3	167,05	151,39	9,38%		
4	167,05	151,70	9,19%		
5	139,70	164,80	17,97%		
6	63,13	153,39	142,98%		
7	118,95	152,34	28,07%		
8	370,79	151,39	59,17%		
9	290,47	151,70	47,77%		
MAPE			48,91%		

Model 2

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	174,68	31,08%		0,01
2	72,36	181,29	150,54%		
3	167,05	180,74	8,19%		
4	167,05	180,55	8,08%		
5	139,70	108,69	22,20%		
6	63,13	174,68	176,70%		
7	118,95	181,29	52,41%		
8	370,79	180,74	51,26%		
9	290,47	180,55	37,84%		
MAPE			59,81%		

Model 3

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	173,54	30,23%		0,01
2	72,36	178,91	147,25%		
3	167,05	178,17	6,66%		
4	167,05	178,13	6,63%		
5	139,70	113,38	18,84%		
6	63,13	173,54	174,90%		
7	118,95	178,91	50,41%		
8	370,79	178,17	51,95%		
9	290,47	178,13	38,68%		
MAPE			58,39%		

Model 4

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	155,07	16,37%		0,01
2	72,36	154,13	113,01%		
3	167,05	152,25	8,86%		
4	167,05	152,82	8,52%		
5	139,70	165,68	18,60%		
6	63,13	155,07	145,64%		
7	118,95	154,13	29,58%		
8	370,79	152,25	58,94%		
9	290,47	152,82	47,39%		
MAPE			49,66%		

Model 5

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	153,49	15,18%		0,01
2	72,36	152,57	110,85%		
3	167,05	150,68	9,80%		
4	167,05	151,24	9,46%		
5	139,70	167,57	19,95%		
6	63,13	153,49	143,13%		
7	118,95	152,57	28,27%		
8	370,79	150,68	59,36%		
9	290,47	151,24	47,93%		
MAPE			49,33%		

Model 6

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	153,49	15,18%		0,01
2	72,36	152,64	110,94%		
3	167,05	150,68	9,80%		
4	167,05	151,25	9,46%		
5	139,70	167,46	19,87%		
6	63,13	153,49	143,13%		
7	118,95	152,64	28,32%		
8	370,79	150,68	59,36%		
9	290,47	151,25	47,93%		
MAPE			49,33%		

Model 7

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	170,76	28,14%		0,02
2	72,36	177,14	144,80%		
3	167,05	179,70	7,57%		
4	167,05	178,66	6,95%		
5	139,70	116,94	16,29%		
6	63,13	170,76	170,49%		
7	118,95	177,14	48,92%		
8	370,79	179,70	51,53%		
9	290,47	178,66	38,49%		
MAPE			57,02%		

Model 8

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	173,69	30,34%		0,02
2	72,36	179,66	148,29%		
3	167,05	180,22	7,89%		
4	167,05	179,78	7,62%		
5	139,70	108,92	22,03%		
6	63,13	173,69	175,14%		
7	118,95	179,66	51,04%		
8	370,79	180,22	51,40%		
9	290,47	179,78	38,11%		
MAPE			59,09%		

Model 9

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	153,73	15,36%		0,02
2	72,36	152,73	111,07%		
3	167,05	150,82	9,71%		
4	167,05	151,39	9,37%		
5	139,70	167,84	20,14%		
6	63,13	153,73	143,51%		
7	118,95	152,73	28,40%		
8	370,79	150,82	59,32%		
9	290,47	151,39	47,88%		
MAPE			49,42%		

Model 10

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,18	26,20%		0,02
2	72,36	175,72	142,84%		
3	167,05	179,11	7,22%		
4	167,05	177,69	6,37%		
5	139,70	126,18	9,68%		
6	63,13	168,18	166,40%		
7	118,95	175,72	47,73%		
8	370,79	179,11	51,70%		
9	290,47	177,69	38,83%		
MAPE			55,22%		

Model 11

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	168,65	26,56%	168,65		0,02
2	177,22	144,92%	177,22		
3	180,74	8,19%	180,74		
4	179,26	7,31%	179,26		
5	128,23	8,21%	128,23		
6	168,65	167,15%	168,65		
7	177,22	48,99%	177,22		
8	180,74	51,26%	180,74		
9	179,26	38,28%	179,26		
MAPE			55,65%		

Model 12

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	171,34	28,57%		0,02
2	72,36	178,31	146,41%		
3	167,05	179,95	7,72%		
4	167,05	179,10	7,21%		
5	139,70	115,19	17,54%		
6	63,13	171,34	171,41%		
7	118,95	178,31	49,90%		
8	370,79	179,95	51,47%		
9	290,47	179,10	38,34%		
MAPE			57,62%		

Model 13

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	169,58	27,25%		0,04
2	72,36	176,65	144,13%		
3	167,05	179,98	7,74%		
4	167,05	178,68	6,96%		
5	139,70	122,41	12,38%		
6	63,13	169,58	168,62%		
7	118,95	176,65	48,51%		
8	370,79	179,98	51,46%		
9	290,47	178,68	38,49%		
MAPE			56,17%		

Model 14

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	165,32	24,06%		0,04
2	72,36	173,80	140,18%		
3	167,05	181,42	8,60%		
4	167,05	178,49	6,85%		
5	139,70	129,92	7,00%		
6	63,13	165,32	161,87%		
7	118,95	173,80	46,11%		
8	370,79	181,42	51,07%		
9	290,47	178,49	38,55%		
MAPE			53,81%		

Model 15

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	172,40	29,37%		0,04
2	72,36	178,42	146,57%		
3	167,05	180,45	8,02%		
4	167,05	179,60	7,51%		
5	139,70	111,82	19,96%		
6	63,13	172,40	173,09%		
7	118,95	178,42	49,99%		
8	370,79	180,45	51,33%		
9	290,47	179,60	38,17%		
MAPE			58,22%		

Model 16

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,43	23,39%		0,04
2	72,36	173,10	139,22%		
3	167,05	181,96	8,93%		
4	167,05	178,60	6,92%		
5	139,70	136,57	2,24%		
6	63,13	164,43	160,47%		
7	118,95	173,10	45,52%		
8	370,79	181,96	50,93%		
9	290,47	178,60	38,51%		
MAPE			52,90%		

Model 17

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	166,05	24,61%		0,04
2	72,36	174,52	141,19%		
3	167,05	181,06	8,39%		
4	167,05	178,55	6,88%		
5	139,70	129,16	7,55%		
6	63,13	166,05	163,03%		
7	118,95	174,52	46,72%		
8	370,79	181,06	51,17%		
9	290,47	178,55	38,53%		
MAPE			54,23%		

Model 18

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	178,02	33,58%		0,04
2	72,36	175,70	142,81%		
3	167,05	188,04	12,56%		
4	167,05	185,78	11,21%		
5	139,70	121,01	13,38%		
6	63,13	178,02	181,98%		
7	118,95	175,70	47,71%		
8	370,79	188,04	49,29%		
9	290,47	185,78	36,04%		
MAPE			58,73%		

Model 19

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	169,11	26,90%		0,06
2	72,36	175,91	143,11%		
3	167,05	179,36	7,37%		
4	167,05	178,03	6,57%		
5	139,70	122,00	12,67%		
6	63,13	169,11	167,88%		
7	118,95	175,91	47,89%		
8	370,79	179,36	51,63%		
9	290,47	178,03	38,71%		
MAPE			55,86%		

Model 20

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	170,02	27,58%		0,06
2	72,36	176,92	144,51%		
3	167,05	179,62	7,52%		
4	167,05	178,48	6,84%		
5	139,70	119,07	14,77%		
6	63,13	170,02	169,31%		
7	118,95	176,92	48,74%		
8	370,79	179,62	51,56%		
9	290,47	178,48	38,55%		
MAPE			56,60%		

Model 21

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,14	23,17%		0,06
2	72,36	172,84	138,86%		
3	167,05	182,65	9,34%		
4	167,05	178,97	7,13%		
5	139,70	131,51	5,86%		
6	63,13	164,14	160,00%		
7	118,95	172,84	45,30%		
8	370,79	182,65	50,74%		
9	290,47	178,97	38,39%		
MAPE			53,20%		

Model 22

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	170,64	28,05%		0,06
2	72,36	177,10	144,75%		
3	167,05	179,46	7,43%		
4	167,05	178,45	6,82%		
5	139,70	114,96	17,71%		
6	63,13	170,64	170,31%		
7	118,95	177,10	48,89%		
8	370,79	179,46	51,60%		
9	290,47	178,45	38,57%		
MAPE			57,12%		

Model 23

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	170,13	27,67%		0,06
2	72,36	176,89	144,45%		
3	167,05	179,55	7,48%		
4	167,05	178,43	6,81%		
5	139,70	117,77	15,70%		
6	63,13	170,13	169,49%		
7	118,95	176,89	48,71%		
8	370,79	179,55	51,58%		
9	290,47	178,43	38,57%		
MAPE			56,72%		

Model 24

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	167,15	25,43%		0,06
2	72,36	175,24	142,17%		
3	167,05	180,03	7,77%		
4	167,05	178,15	6,65%		
5	139,70	127,54	8,70%		
6	63,13	167,15	164,76%		
7	118,95	175,24	47,32%		
8	370,79	180,03	51,45%		
9	290,47	178,15	38,67%		
MAPE			54,77%		

Model 25

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	167,37	25,60%		0,08
2	72,36	174,54	141,20%		
3	167,05	179,50	7,45%		
4	167,05	177,71	6,38%		
5	139,70	128,23	8,21%		
6	63,13	167,37	165,12%		
7	118,95	174,54	46,73%		
8	370,79	179,50	51,59%		
9	290,47	177,71	38,82%		
MAPE			54,57%		

Model 26

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,60	22,77%		0,08
2	72,36	170,30	135,35%		
3	167,05	182,89	9,48%		
4	167,05	178,39	6,79%		
5	139,70	122,22	12,51%		
6	63,13	163,60	159,14%		
7	118,95	170,30	43,17%		
8	370,79	182,89	50,67%		
9	290,47	178,39	38,58%		
MAPE			53,16%		

Model 27

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,85	26,71%		0,08
2	72,36	175,97	143,19%		
3	167,05	179,86	7,67%		
4	167,05	178,39	6,79%		
5	139,70	124,70	10,74%		
6	63,13	168,85	167,47%		
7	118,95	175,97	47,94%		
8	370,79	179,86	51,49%		
9	290,47	178,39	38,59%		
MAPE			55,62%		

Model 28

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,20	22,47%		0,08
2	72,36	171,33	136,77%		
3	167,05	182,16	9,05%		
4	167,05	177,72	6,39%		
5	139,70	124,97	10,54%		
6	63,13	163,20	158,52%		
7	118,95	171,33	44,03%		
8	370,79	182,16	50,87%		
9	290,47	177,72	38,81%		
MAPE			53,05%		

Model 29

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	155,37	16,60%		0,08
2	72,36	164,32	127,09%		
3	167,05	172,24	3,11%		
4	167,05	169,07	1,21%		
5	139,70	125,54	10,14%		
6	63,13	155,37	146,12%		
7	118,95	164,32	38,15%		
8	370,79	172,24	53,55%		
9	290,47	169,07	41,79%		
MAPE			48,64%		

Model 30

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,79	23,66%		0,08
2	72,36	173,42	139,66%		
3	167,05	182,44	9,21%		
4	167,05	178,96	7,13%		
5	139,70	139,43	0,20%		
6	63,13	164,79	161,04%		
7	118,95	173,42	45,79%		
8	370,79	182,44	50,80%		
9	290,47	178,96	38,39%		
MAPE			52,87%		

Model 31

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	167,51	25,70%		0,10
2	72,36	174,73	141,47%		
3	167,05	179,56	7,49%		
4	167,05	177,81	6,44%		
5	139,70	128,29	8,17%		
6	63,13	167,51	165,34%		
7	118,95	174,73	46,89%		
8	370,79	179,56	51,57%		
9	290,47	177,81	38,78%		
MAPE			54,65%		

Model 32

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,46	26,41%		0,10
2	72,36	175,46	142,48%		
3	167,05	179,42	7,41%		
4	167,05	177,93	6,51%		
5	139,70	124,96	10,55%		
6	63,13	168,46	166,84%		
7	118,95	175,46	47,50%		
8	370,79	179,42	51,61%		
9	290,47	177,93	38,74%		
MAPE			55,34%		

Model 33

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	169,42	27,13%		0,10
2	72,36	176,60	144,05%		
3	167,05	179,80	7,63%		
4	167,05	178,51	6,86%		
5	139,70	122,24	12,50%		
6	63,13	169,42	168,36%		
7	118,95	176,60	48,46%		
8	370,79	179,80	51,51%		
9	290,47	178,51	38,55%		
MAPE			56,12%		

Model 34

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	166,63	25,04%		0,10
2	72,36	175,26	142,21%		
3	167,05	185,45	11,01%		
4	167,05	181,54	8,68%		
5	139,70	132,32	5,28%		
6	63,13	166,63	163,94%		
7	118,95	175,26	47,34%		
8	370,79	185,45	49,99%		
9	290,47	181,54	37,50%		
MAPE			54,56%		

Model 35

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,74	22,87%		0,10
2	72,36	171,93	137,60%		
3	167,05	182,46	9,22%		
4	167,05	178,56	6,89%		
5	139,70	132,07	5,46%		
6	63,13	163,74	159,36%		
7	118,95	171,93	44,54%		
8	370,79	182,46	50,79%		
9	290,47	178,56	38,53%		
MAPE			52,81%		

Model 36

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	166,79	25,16%		0,10
2	72,36	175,44	142,46%		
3	167,05	180,86	8,27%		
4	167,05	178,73	6,99%		
5	139,70	129,65	7,20%		
6	63,13	166,79	164,19%		
7	118,95	175,44	47,49%		
8	370,79	180,86	51,22%		
9	290,47	178,73	38,47%		
MAPE			54,61%		

Model 37

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	159,88	19,98%		0,14
2	72,36	168,43	132,77%		
3	167,05	183,16	9,64%		
4	167,05	178,19	6,67%		
5	139,70	140,08	0,27%		
6	63,13	159,88	153,25%		
7	118,95	168,43	41,60%		
8	370,79	183,16	50,60%		
9	290,47	178,19	38,65%		
MAPE			50,38%		

Model 38

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,19	22,46%		0,14
2	72,36	172,59	138,51%		
3	167,05	181,54	8,68%		
4	167,05	177,83	6,46%		
5	139,70	131,87	5,60%		
6	63,13	163,19	158,50%		
7	118,95	172,59	45,09%		
8	370,79	181,54	51,04%		
9	290,47	177,83	38,78%		
MAPE			52,79%		

Model 39

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,44	22,65%		0,14
2	72,36	171,88	137,53%		
3	167,05	182,67	9,35%		
4	167,05	178,28	6,72%		
5	139,70	127,06	9,05%		
6	63,13	163,44	158,90%		
7	118,95	171,88	44,50%		
8	370,79	182,67	50,74%		
9	290,47	178,28	38,62%		
MAPE			53,12%		

Model 40

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	167,59	25,76%		0,14
2	72,36	175,47	142,50%		
3	167,05	179,61	7,52%		
4	167,05	177,88	6,48%		
5	139,70	127,40	8,81%		
6	63,13	167,59	165,47%		
7	118,95	175,47	47,52%		
8	370,79	179,61	51,56%		
9	290,47	177,88	38,76%		
MAPE			54,93%		

Model 41

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	169,56	27,24%		0,14
2	72,36	175,22	142,16%		
3	167,05	179,02	7,16%		
4	167,05	177,68	6,36%		
5	139,70	120,32	13,87%		
6	63,13	169,56	168,59%		
7	118,95	175,22	47,31%		
8	370,79	179,02	51,72%		
9	290,47	177,68	38,83%		
MAPE			55,92%		

Model 42

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	170,39	27,87%		0,14
2	72,36	177,44	145,22%		
3	167,05	179,57	7,50%		
4	167,05	178,58	6,90%		
5	139,70	117,19	16,11%		
6	63,13	170,39	169,91%		
7	118,95	177,44	49,17%		
8	370,79	179,57	51,57%		
9	290,47	178,58	38,52%		
MAPE			56,98%		

Model 43

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	165,02	23,83%		0,18
2	72,36	172,91	138,96%		
3	167,05	181,00	8,35%		
4	167,05	178,24	6,70%		
5	139,70	132,55	5,12%		
6	63,13	165,02	161,40%		
7	118,95	172,91	45,37%		
8	370,79	181,00	51,19%		
9	290,47	178,24	38,64%		
MAPE			53,28%		

Model 44

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,53	26,46%		0,18
2	72,36	178,45	146,61%		
3	167,05	188,06	12,57%		
4	167,05	184,27	10,31%		
5	139,70	136,48	2,31%		
6	63,13	168,53	166,95%		
7	118,95	178,45	50,02%		
8	370,79	188,06	49,28%		
9	290,47	184,27	36,56%		
MAPE			55,67%		

Model 45

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,01	26,08%		0,18
2	72,36	175,64	142,73%		
3	167,05	179,01	7,16%		
4	167,05	177,60	6,32%		
5	139,70	125,69	10,03%		
6	63,13	168,01	166,13%		
7	118,95	175,64	47,66%		
8	370,79	179,01	51,72%		
9	290,47	177,60	38,86%		
MAPE			55,19%		

Model 46

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,11	23,15%		0,18
2	72,36	173,06	139,16%		
3	167,05	182,24	9,09%		
4	167,05	178,58	6,90%		
5	139,70	129,34	7,42%		
6	63,13	164,11	159,95%		
7	118,95	173,06	45,49%		
8	370,79	182,24	50,85%		
9	290,47	178,58	38,52%		
MAPE			53,39%		

Model 47

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,44	26,40%		0,18
2	72,36	175,92	143,11%		
3	167,05	179,43	7,41%		
4	167,05	178,01	6,56%		
5	139,70	124,78	10,68%		
6	63,13	168,44	166,81%		
7	118,95	175,92	47,89%		
8	370,79	179,43	51,61%		
9	290,47	178,01	38,72%		
MAPE			55,47%		

Model 48

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,11	23,15%		0,18
2	72,36	173,20	139,36%		
3	167,05	182,23	9,09%		
4	167,05	178,55	6,88%		
5	139,70	130,08	6,88%		
6	63,13	164,11	159,96%		
7	118,95	173,20	45,61%		
8	370,79	182,23	50,85%		
9	290,47	178,55	38,53%		
MAPE			53,37%		

Model 49

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	162,69	22,09%		0,20
2	72,36	170,80	136,04%		
3	167,05	182,16	9,04%		
4	167,05	178,32	6,75%		
5	139,70	136,02	2,63%		
6	63,13	162,69	157,71%		
7	118,95	170,80	43,59%		
8	370,79	182,16	50,87%		
9	290,47	178,32	38,61%		
MAPE			51,93%		

Model 50

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	168,19	26,21%		0,20
2	72,36	175,56	142,62%		
3	167,05	179,55	7,48%		
4	167,05	178,01	6,56%		
5	139,70	126,17	9,68%		
6	63,13	168,19	166,42%		
7	118,95	175,56	47,59%		
8	370,79	179,55	51,58%		
9	290,47	178,01	38,72%		
MAPE			55,21%		

Model 51

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	163,74	22,88%		0,20
2	72,36	173,15	139,29%		
3	167,05	182,54	9,27%		
4	167,05	178,69	6,97%		
5	139,70	130,97	6,25%		
6	63,13	163,74	159,38%		
7	118,95	173,15	45,56%		
8	370,79	182,54	50,77%		
9	290,47	178,69	38,48%		
MAPE			53,21%		

Model 52

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	165,02	23,83%		0,20
2	72,36	174,20	140,75%		
3	167,05	183,08	9,60%		
4	167,05	179,56	7,49%		
5	139,70	131,47	5,89%		
6	63,13	165,02	161,40%		
7	118,95	174,20	46,45%		
8	370,79	183,08	50,62%		
9	290,47	179,56	38,18%		
MAPE			53,80%		

Model 53

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	164,02	23,08%		0,20
2	72,36	171,61	137,16%		
3	167,05	182,01	8,95%		
4	167,05	178,19	6,67%		
5	139,70	119,16	14,70%		
6	63,13	164,02	159,82%		
7	118,95	171,61	44,27%		
8	370,79	182,01	50,91%		
9	290,47	178,19	38,66%		
MAPE			53,80%		

Model 54

Data ke-	Data Aktual	Hasil Peramalan	Persentase Error	Arsitektur	LR
1	133,26	166,71	25,10%		0,20
2	72,36	175,61	142,69%		
3	167,05	181,20	8,47%		
4	167,05	178,99	7,15%		
5	139,70	130,23	6,78%		
6	63,13	166,71	164,07%		
7	118,95	175,61	47,63%		
8	370,79	181,20	51,13%		
9	290,47	178,99	38,38%		
MAPE			54,60%		

LAMPIRAN 4

Hasil Prediksi Terbaik Normalisasi Min-Max

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Ampelgading	204,75	169,56	17,19%
Bantur	204,75	182,92	10,66%
Bululawang	204,75	198,68	2,97%
Dampit	204,75	172,58	15,71%
Dau	204,75	189,74	7,33%
Donomulyo	204,75	165,58	19,13%
Gedangan	204,75	172,15	15,92%
Gondanglegi	204,75	184,28	10,00%
Jabung	204,75	181,14	11,53%
Kalipare	204,75	173,20	15,41%
Karangploso	204,75	198,36	3,12%
Kepanjen	204,75	205,54	0,38%
Kromengan	204,75	210,38	2,75%
Lawang	204,75	201,60	1,54%
Ngajum	204,75	201,81	1,44%
Ngantang	204,75	187,39	8,48%
Pagak	204,75	205,29	0,26%
Pagelaran	204,75	210,06	2,59%
Pakis	204,75	205,53	0,38%
Pakisaji	204,75	210,00	2,56%
Poncokusumo	204,75	172,80	15,61%
Pujon	204,75	189,09	7,65%
Singosari	204,75	196,26	4,15%
Sumbermanjing	204,75	168,73	17,59%
Sumberpucung	204,75	207,51	1,35%
Tajinan	204,75	189,60	7,40%
Tirtoyudo	204,75	173,93	15,05%
Tumpang	204,75	190,09	7,16%
Turen	204,75	202,78	0,96%
Wagir	204,75	206,13	0,67%
Wajak	204,75	185,09	9,60%
Wonosari	204,75	187,64	8,36%
Kasembon	204,75	207,07	1,13%
Blimbing	315,00	168,55	46,49%
Kedungkandang	204,00	212,46	4,15%
Klojen	204,00	184,13	9,74%
Lowokwaru	204,00	172,17	15,60%
Sukun	270,00	217,73	19,36%
Batu	194,00	187,67	3,26%
Bumiaji	194,00	178,39	8,04%
Junrejo	194,00	186,59	3,82%
Purwodadi	336,08	309,20	8,00%
Tutur	336,08	328,25	2,33%
Puspo	336,08	340,19	1,23%
Tosari	336,08	324,57	3,42%
Lumbang	336,08	282,11	16,06%
Pasrepan	336,08	326,76	2,77%
Kejayan	336,08	324,08	3,57%

Lanjutan Tabel Lampiran 4

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Wonorejo	336,08	333,90	0,65%
Purwosari	336,08	332,69	1,01%
Prigen	336,08	294,86	12,26%
Sukorejo	336,08	334,79	0,38%
Pandaan	336,08	325,18	3,24%
Gempol	336,08	321,78	4,25%
Beji	336,08	303,90	9,57%
Bangil	336,08	288,97	14,02%
Rembang	336,08	336,76	0,20%
Kraton	336,08	316,80	5,74%
Pohjentrek	336,08	214,39	36,21%
Gondangwetan	336,08	304,94	9,27%
Rejoso	336,08	299,95	10,75%
Winongan	336,08	324,25	3,52%
Grati	336,08	334,13	0,58%
Lekok	336,08	321,40	4,37%
Nguling	336,08	179,97	46,45%
Gadingrejo	23,18	25,67	10,71%
Purworejo	23,18	63,92	175,72%
Bugulkidul	23,18	46,28	99,61%
Panggungrejo	23,18	26,34	13,60%
Manguharjo	174,92	160,72	8,12%
Taman	279,17	180,17	35,46%
Kartoharjo	279,17	182,52	34,62%
Kebonsari	165,08	168,56	2,11%
Geger	165,08	167,78	1,64%
Dolopo	123,67	136,60	10,46%
Dagangan	121,08	127,39	5,21%
Wungu	183,92	184,61	0,38%
Kare	183,92	167,56	8,89%
Gemarang	175,08	171,26	2,18%
Saradan	220,83	177,94	19,42%
Pilangkenceng	220,83	209,99	4,91%
Mejayan	183,17	182,86	0,17%
Wonoasri	160,00	162,48	1,55%
Balerejo	149,83	152,60	1,85%
Madiun	163,92	165,07	0,71%
Sawahan	178,67	172,27	3,58%
Jiwan	198,43	186,78	5,87%
Besuki	217,75	201,66	7,39%
Bandung	160,83	156,91	2,44%
Pakel	165,67	159,11	3,96%
Campurdarat	165,67	156,55	5,50%
Tanggung gunung	170,58	168,17	1,41%
Kalidawir	120,67	130,99	8,55%
Pucanglaban	120,67	128,61	6,58%
Rejotangan	138,75	144,37	4,05%
Ngunut	141,50	144,03	1,79%

Lanjutan Tabel Lampiran 4

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Sumbergempol	155,42	155,06	0,23%
Boyolangu	138,75	144,20	3,93%
Tulungagung	155,42	146,19	5,94%
Kedungwaru	155,42	154,02	0,90%
Ngantru	159,00	159,50	0,31%
Karangrejo	196,50	186,77	4,95%
Kauman	162,83	159,49	2,05%
Gondang	175,83	171,63	2,39%
Pagerwojo	220,08	212,19	3,59%
Sendang	252,67	235,57	6,77%
Bakung	149,25	155,15	3,95%
Wonotirto	11,17	57,83	417,92%
Panggunrejo	174,08	167,78	3,62%
Wates	174,08	177,65	2,05%
Binangun	174,08	175,72	0,94%
Sutojayan	311,83	319,88	2,58%
Kademangan	105,33	122,09	15,91%
Kanigoro	152,00	158,27	4,12%
Talun	650,25	630,35	3,06%
Selopuro	180,17	177,05	1,73%
Kesamben	201,75	203,01	0,63%
Selorejo	174,08	179,52	3,12%
Doko	932,58	882,59	5,36%
Wlingi	517,42	406,07	21,52%
Gandusari	678,28	669,51	1,29%
Garum	81,33	90,01	10,67%
Nglegok	978,00	957,73	2,07%
Sanankulon	172,75	173,91	0,67%
Ponggok	28,17	44,87	59,31%
Srengat	165,17	168,82	2,21%
Wonodadi	189,25	190,40	0,61%
Udanawu	189,25	186,99	1,20%
MAPE			12,82%

LAMPIRAN 5

Hasil Prediksi Terbaik Normalisasi Zscore

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Ampelgading	204,75	251,25	22,71%
Bantur	204,75	251,25	22,71%
Bululawang	204,75	251,13	22,65%
Dampit	204,75	251,25	22,71%
Dau	204,75	205,72	0,48%
Donomulyo	204,75	251,25	22,71%
Gedangan	204,75	251,25	22,71%
Gondanglegi	204,75	251,25	22,71%
Jabung	204,75	251,25	22,71%
Kalipare	204,75	251,25	22,71%
Karangploso	204,75	251,18	22,68%
Kepanjen	204,75	251,15	22,66%
Kromengan	204,75	250,96	22,57%
Lawang	204,75	251,16	22,67%
Ngajum	204,75	251,25	22,71%
Ngantang	204,75	251,25	22,71%
Pagak	204,75	251,25	22,71%
Pagelaran	204,75	251,24	22,71%
Pakis	204,75	248,82	21,52%
Pakisaji	204,75	250,42	22,30%
Poncokusumo	204,75	251,25	22,71%
Pujon	204,75	251,25	22,71%
Singosari	204,75	251,25	22,71%
Sumbermanjing	204,75	251,25	22,71%
Sumberpucung	204,75	250,99	22,58%
Tajinan	204,75	248,59	21,41%
Tirtoyudo	204,75	251,25	22,71%
Tumpang	204,75	251,23	22,70%
Turen	204,75	251,25	22,71%
Wagir	204,75	251,25	22,71%
Wajak	204,75	251,25	22,71%
Wonosari	204,75	250,92	22,55%
Kasembon	204,75	249,80	22,00%
Blimbing	315,00	315,04	0,01%
Kedungkandang	204,00	241,82	18,54%
Klojen	204,00	205,66	0,81%
Lowokwaru	204,00	204,01	0,01%
Sukun	270,00	519,99	92,59%
Batu	194,00	207,44	6,93%
Bumiaji	194,00	289,08	49,01%
Junrejo	194,00	205,80	6,08%
Purwodadi	336,08	671,73	99,87%
Tutur	336,08	671,73	99,87%
Puspo	336,08	671,73	99,87%
Tosari	336,08	671,73	99,87%
Lumbang	336,08	670,92	99,63%
Pasrepan	336,08	671,73	99,87%
Kejayan	336,08	671,73	99,87%

Lanjutan Tabel Lampiran 5

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Wonorejo	336,08	671,73	99,87%
Purwosari	336,08	671,73	99,87%
Prigen	336,08	671,73	99,87%
Sukorejo	336,08	671,73	99,87%
Pandaan	336,08	671,72	99,87%
Gempol	336,08	671,73	99,87%
Beji	336,08	671,71	99,87%
Bangil	336,08	671,69	99,86%
Rembang	336,08	671,73	99,87%
Kraton	336,08	671,72	99,87%
Pohjentrek	336,08	662,11	97,01%
Gondangwetan	336,08	671,70	99,87%
Rejoso	336,08	671,71	99,87%
Winongan	336,08	671,72	99,87%
Grati	336,08	671,73	99,87%
Lekok	336,08	671,73	99,87%
Nguling	336,08	514,70	53,15%
Gadingrejo	23,18	23,18	0,00%
Purworejo	23,18	23,18	0,00%
Bugulkidul	23,18	23,18	0,00%
Panggunrejo	23,18	23,18	0,00%
Manguharjo	174,92	174,92	0,00%
Taman	279,17	279,20	0,01%
Kartoharjo	279,17	279,31	0,05%
Kebonsari	165,08	165,08	0,00%
Geger	165,08	165,08	0,00%
Dolopo	123,67	123,67	0,00%
Dagangan	121,08	121,08	0,00%
Wungu	183,92	183,92	0,00%
Kare	183,92	186,03	1,15%
Gemarang	175,08	175,08	0,00%
Saradan	220,83	270,98	22,71%
Pilangkenceng	220,83	271,14	22,78%
Mejayan	183,17	183,17	0,00%
Wonoasri	160,00	160,00	0,00%
Balerejo	149,83	149,83	0,00%
Madiun	163,92	163,92	0,00%
Sawahan	178,67	178,67	0,00%
Jiwan	198,43	198,44	0,00%
Besuki	217,75	309,84	42,29%
Bandung	160,83	160,83	0,00%
Pakel	165,67	165,67	0,00%
Campurdarat	165,67	165,67	0,00%
Tanggung gunung	170,58	170,58	0,00%
Kalidawir	120,67	120,67	0,00%
Pucanglaban	120,67	120,67	0,00%
Rejotangan	138,75	138,75	0,00%
Ngunut	141,50	141,50	0,00%
Sumbergempol	155,42	155,42	0,00%
Boyolangu	138,75	138,75	0,00%
Tulungagung	155,42	155,42	0,00%

Lanjutan Tabel Lampiran 5

Nama Daerah	Curah Hujan Aktual	Curah Hujan Prediksi	Persentase Error
Kedungwaru	155,42	155,42	0,00%
Ngantru	159,00	159,00	0,00%
Karangrejo	196,50	206,38	5,03%
Kauman	162,83	162,83	0,00%
Gondang	175,83	175,83	0,00%
Pagerwojo	220,08	275,06	24,98%
Sendang	252,67	503,08	99,10%
Bakung	149,25	149,25	0,00%
Wonotirto	11,17	11,17	0,00%
Panggunrejo	174,08	174,08	0,00%
Wates	174,08	174,08	0,00%
Binangun	174,08	174,08	0,00%
Sutojayan	311,83	622,37	99,59%
Kademangan	105,33	105,33	0,00%
Kanigoro	152,00	152,00	0,00%
Talun	650,25	1297,82	99,59%
Selopuro	180,17	180,18	0,01%
Kesamben	201,75	247,01	22,44%
Selorejo	174,08	174,08	0,00%
Doko	932,58	1861,32	99,59%
Wlingi	517,42	1032,70	99,59%
Gandusari	678,28	1353,77	99,59%
Garum	81,33	81,33	0,00%
Sutojayan	311,83	622,37	99,59%
Kademangan	105,33	105,33	0,00%
Kanigoro	152,00	152,00	0,00%
Talun	650,25	1297,82	99,59%
Selopuro	180,17	180,18	0,01%
Kesamben	201,75	247,01	22,44%
Selorejo	174,08	174,08	0,00%
Doko	932,58	1861,32	99,59%
Wlingi	517,42	1032,70	99,59%
Gandusari	678,28	1353,77	99,59%
Garum	81,33	81,33	0,00%
Nglegok	978,00	1951,97	99,59%
Sanankulon	172,75	172,75	0,00%
Ponggok	28,17	28,17	0,00%
Srengat	165,17	165,17	0,00%
Wonodadi	189,25	205,61	8,64%
Udanawu	189,25	193,42	2,20%
MAPE			31,98%