

PREDIKSI HUJAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK*

SKRIPSI

**Oleh :
ABIDZAR ALGHIFARI FIQYAN
NIM. 18650102**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

PREDIKSI HUJAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK*

SKRIPSI

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)**

**Oleh :
ABIDZAR ALGHIFARI FIQYAN
NIM. 18650102**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

PREDIKSI HUJAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK*

SKRIPSI

Oleh :
ABIDZAR ALGHIFARI FIQYAN
NIM. 18650102

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2025

Pembimbing I,



Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Pembimbing II,



Dr. M. Imamudin Lc, MA
NIP. 19740602 200901 1 010

Mengetahui,

Ketua Program Studi Teknik Informatika

Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. H. Bachrul Kurniawan S.T., M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PREDIKSI HUJAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK*

SKRIPSI

Oleh :
ABIDZAR ALGHIFARI FIQYAN
NIM. 18650102

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 25 Juni 2025

Susunan Dewan Penguji

Ketua Penguji : Dr. Ir. Fachrul Kurniawan S.T., M.MT., IPU
NIP. 19771020 200912 1 001

Anggota Penguji I : Fatchurrohman, M.Kom
NIP. 19700731 200501 1 002

Anggota Penguji II : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Anggota Penguji III : Dr. M. Imamudin Lc, MA
NIP. 19740602 200901 1 010

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



Fachrul Kurniawan S.T., M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Abidzar Alghifari Fiqyan

NIM : 18650102

Fakultas / Program Studi: Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Prediksi Hujan Menggunakan *Artificial Neural Network*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan 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 merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 25 Juni 2025
Yang membuat pernyataan,



Abidzar Alghifari Fiqyan
NIM. 18650102

MOTTO

فَإِنَّ مَعَ الْعُسْرِ يُسْرًا ۖ إِنَّ مَعَ الْعُسْرِ يُسْرًا ۚ

*“Maka, sesungguhnya beserta kesulitan ada kemudahan(5). Sesungguhnya
beserta kesulitan ada kemudahan(6).” Qs. Al-Insyirah*

HALAMAN PERSEMBAHAN

اَلْحَمْدُ لِلّٰهِ رَبِّ الْعَالَمِيْنَ

Karya ini dipersembahkan dengan penuh rasa syukur dan hormat kepada:

Allah SWT, *Rabb* semesta alam,

Yang telah memberikan segala nikmat iman, kesehatan, ilmu, serta kekuatan
hingga skripsi ini dapat terselesaikan.

Nabi Muhammad SAW, suri teladan sepanjang zaman,

Yang telah menjadi teladan hidup dan inspirasi bagi umat muslim.

Abi saya M. Taufiq, Uma saya Mujianti, Adik saya Almer dan Keluarga tercinta,

Yang senantiasa berdoa dan menyemangati penulis sampai titik ini.

Dospem saya Pak Zainal dan Pak Imam,

Yang dengan penuh kesabaran dan keikhlasan telah membimbing dan
mengarahkan penulis dalam menyusun skripsi ini

Teman-teman seperjuangan,

Yang telah menjadi bagian dari proses panjang ini dengan doa dan semangat yang
tak ternilai.

KATA PENGANTAR

Assalamu'alaikum warahmatullahi wabarakatuh.

Segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu wa Ta'ala, karena dengan rahmat, taufik, dan hidayah-Nya, penulis dapat menyelesaikan skripsi yang berjudul: "Prediksi Hujan Menggunakan Metode *Artificial Neural Network*" sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknik Informatika jenjang Strata-1 Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Shalawat serta salam semoga selalu ter kepada Nabi Muhammad SAW, beserta keluarga, para sahabat, dan seluruh umatnya yang *istiqamah* di jalan Islam hingga akhir zaman.

Skripsi ini tidak mungkin terselesaikan tanpa bantuan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis menyampaikan rasa terima kasih dan penghargaan sebesar-besarnya kepada:

1. Prof. Dr. M. Zainuddin, MA selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan S.T., M.MT., IPU selaku Ketua Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang sekaligus dosen ketua penguji yang telah berkenan mengoreksi dan memberikan saran untuk kebaikan penulis.

4. Dr. Zainal Abidin, M.Kom selaku dosen pembimbing pertama yang telah meluangkan waktunya untuk membimbing dan memberikan arahan.
5. Dr. M. Imamudin Lc, MA selaku dosen pembimbing kedua yang telah meluangkan waktunya untuk membimbing dan memberikan arahan.
6. Juniardi Nur Fadila, M.T selaku wali dosen yang telah berkenan mengoreksi dan memberikan saran untuk kebaikan penulis.
7. Fatchurrohman, M.Kom selaku dosen penguji kedua yang telah berkenan meluangkan waktunya untuk membimbing dan memberikan arahan.
8. Kedua orang tua tercinta, atas doa, kasih sayang, dan dukungan tiada henti dalam setiap langkah hidup penulis.
9. Teman-teman seperjuangan, yang telah menjadi bagian dari proses panjang ini dengan doa dan semangat yang tak ternilai.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, penulis dengan lapang dada menerima segala kritik dan saran yang membangun, demi penyempurnaan di masa yang akan datang. Semoga karya sederhana ini dapat memberikan manfaat dan menjadi amal kebaikan di sisi Allah SWT.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 25 Juni 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
ABSTRAK	xiv
ABSTRACT	xv
الملخص	xvi
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	4
1.1 Batasan Masalah	4
1.3. Tujuan Penelitian	4
1.4. Manfaat Penelitian	5
BAB II STUDI PUSTAKA	6
2.1. Penelitian Terkait	6
2.2. Hujan	7
2.3. <i>Machine Learning</i>	8
2.4. <i>Artificial Neural Network</i>	9
2.4.1. Struktur ANN	10
BAB III METODOLOGI DAN DESAIN PENELITIAN	13
3.1. Desain Penelitian	13
3.2. Pengumpulan Data	14
3.3. <i>Preprocessing</i> Data	16
3.4. Normalisasi Data	17
3.5. <i>Flowchart</i>	17
3.6. <i>Feature Selection</i>	18
3.6.1. Contoh penerapan <i>PSI Feature Selection</i>	19
3.7. Skenario Uji	22
3.7.1. <i>Confusion Matrix</i>	23
BAB IV HASIL DAN PEMBAHASAN	25
4.1. Implementasi Sistem.....	25
4.2. Hasil uji coba	31
4.3. Pembahasan	38
4.4. Integrasi Islam	39

4.4.1. <i>Mu'amalah ma'a Allah</i>	39
4.4.2. <i>Mu'amalah ma'a an-Nas</i>	41
4.4.3. <i>Mu'amalah ma'a al-Alam</i>	43
BAB V KESIMPULAN DAN SARAN	45
5.1. Kesimpulan	45
5.2. Saran	45
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 2. 1 <i>Single Layer Network</i> (Sumber: Simon Haykin, 2005).....	11
Gambar 2. 2 <i>Multilayer Network</i> (Sumber: Simon Haykin, 2005)	11
Gambar 3. 1 Desain Penelitian.....	13
Gambar 3. 2 <i>Flowchart</i> tahapan prediksi.	18
Gambar 4. 1 Normalisasi.....	27
Gambar 4. 2 Membagi Data <i>Training</i> dan Tes	27
Gambar 4. 3 Model Neural Network.....	28
Gambar 4. 4 <i>Learning rate</i>	29
Gambar 4. 5 <i>Training Model</i>	29
Gambar 4. 6 Evaluasi Model.....	30
Gambar 4. 7 Prediksi.....	30
Gambar 4. 8 Konversi	30
Gambar 4. 9 Hasil pengujian model pertama.....	31
Gambar 4. 10 Hasil Pengujian Model Kedua.....	33
Gambar 4. 11 Hasil Pengujian Model Ketiga	34
Gambar 4. 12 Hasil Pengujian Model Keempat.....	36

DAFTAR TABEL

Tabel 3. 1 <i>Dataset Climate Data Daily</i> IDN.....	15
Tabel 3. 2 Contoh <i>Dataset</i>	20
Tabel 3. 3 Hasil Normalisasi.....	20
Tabel 4. 1 Hasil <i>Confusion Matrix</i> model pertama	31
Tabel 4. 2 Hasil <i>Confusion Matrix</i> model kedua	33
Tabel 4. 3 Hasil <i>Confusion Matrix</i> model ketiga	35
Tabel 4. 4 Hasil <i>Confusion Matrix</i> model keempat	37
Tabel 4. 5 Hasil Evaluasi <i>Artificial Neural Network</i>	39

ABSTRAK

Fiqyan, Abidzar Alghifari. 2025. **Prediksi Hujan Menggunakan Metode *Artificial Neural Network***. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Zainal Abidin, M.Kom (II) Dr. M. Imamudin Lc, MA

Kata kunci: *Variabilitas Hujan, Prediksi, Artificial Neural Network, BMKG, Confusion Matriks*

Indonesia, sebagai negara yang terletak di daerah ekuator dan dikelilingi oleh dua samudra serta dua benua, memiliki iklim yang beragam dan kompleks. Salah satu fenomena alam yang signifikan adalah hujan ekstrem, yang sering kali menyebabkan banjir dan kekeringan, berpotensi merugikan masyarakat dalam berbagai aspek. Variabilitas hujan dipengaruhi oleh berbagai faktor laut-atmosfer, menjadikannya tantangan dalam prediksi dan mitigasi dampaknya. Penelitian ini bertujuan untuk memberikan wawasan lebih mendalam dalam memahami pola hujan serta meningkatkan kewaspadaan dan kesiapsiagaan masyarakat dalam menghadapi fenomena ekstrem. Metode kecerdasan buatan seperti *Artificial Neural Network* telah digunakan. Meskipun menunjukkan hasil yang cukup baik, metode ini masih memerlukan eksplorasi lebih lanjut terutama dalam memahami kompleksitas fitur yang digunakan dalam prediksi. Prediksi yang dilakukan penelitian ini didasarkan dari data hujan yang diambil dari dataset BMKG (Badan Meteorologi, Klimatologi, dan Geofisika). Hasil penelitian menunjukkan bahwa sistem mencapai akurasi prediksi >90% dari pengujian menggunakan *confusion matriks*.

ABSTRACT

Fiqyan, Abidzar Alghifari. 2025. **Rainfall Prediction Using the Artificial Neural Network Method**. Undergraduate Thesis. Informatic Engineering Department The Faculty of Science and Technology Universitas Islam Negeri Maulana Malik Ibrahim Malang. Promotor: (I) Dr. Zainal Abidin, M.Kom (II) Dr. M. Imamudin Lc, MA

Keywords: *Rainfall Variability, Prediction, Artificial Neural Network, BMKG, Confusion Matrics*

Indonesia, as a country located in the equatorial region and surrounded by two oceans and two continents, has a diverse and complex climate. One significant natural phenomenon is extreme rainfall, which often leads to floods and droughts, potentially harming communities in various aspects. Rainfall variability is influenced by multiple ocean-atmosphere factors, making its prediction and impact mitigation a challenge. This study aims to provide deeper insights into rainfall patterns and enhance public awareness and preparedness in facing extreme weather events. Artificial intelligence methods such as Artificial Neural Networks have been employed. While they have shown promising results, further exploration is needed, particularly in understanding the complexity of features used in prediction. The predictions conducted in this study are based on rainfall data obtained from the BMKG (Meteorology, Climatology, and Geophysics Agency) dataset. The results indicate that the system achieves a prediction accuracy of over 90% based on testing using a confusion matrix.

الملخص

فقيان، أيبدر الغيفاري. ٢٠٢٥. التنبؤ بهطول الأمطار باستخدام طريقة الشبكة العصبية الاصطناعية. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: د. زين العابدين، الماجستير؛ المشرف الثاني: د. محمد إمام الدين، الماجستير.

الكلمات الرئيسية: تقلبات هطول أمطار، تنبؤ، شبكة عصبية اصطناعية، هيئة عامة لأرصاد جوية، مصفوفة ارباك

إندونيسيا، كدولة وقعت في منطقة استوائية ومحاطة ببحرين وقارتين، لديها مناخ متنوع ومعقد. من الظواهر الطبيعية الهامة هي الأمطار الغزيرة، التي غالبًا ما تؤدي إلى الفيضانات والجفاف، مما قد يضر المجتمع في جوانب عدة. تتأثر تقلبات هطول الأمطار بعوامل بحرية وجوية متعددة، مما يجعلها تحديًا في التنبؤ وطرق التخفيف من آثارها. هدف هذا البحث إلى تقديم رؤى أعمق لفهم أنماط هطول الأمطار وزيادة وعي المجتمع واستعداده لمواجهة الظواهر المتطرفة. تم استخدام أساليب الذكاء الاصطناعي مثل الشبكة العصبية الاصطناعية. على الرغم من إظهار النتائج الجيدة، إلا أن هذه الطريقة لا تزال بحاجة إلى استكشافات إضافية، خاصة لفهم تعقيد الميزات المستخدمة في التنبؤ. التنبؤات التي أجراها هذا البحث تعتمد على بيانات هطول الأمطار المأخوذة من مجموعة بيانات BMKG (الهيئة العامة لأرصاد الجوية). أظهرت نتائج البحث أن النظام حقق دقة تنبؤ أكثر من ٩٠٪ من الاختبار باستخدام مصفوفة الارباك.

BAB I

PENDAHULUAN

1.1. Latar Belakang

Indonesia adalah negara yang dilewati khatulistiwa dan dikelilingi oleh dua samudra dan dua benua. Indonesia juga menjadi kawasan yang unik di daerah ekuator biasa disebut sebagai Benua Maritim Indonesia (BMI) karena ragam hujan yang cukup besar. Posisi ini menjadikan Indonesia sebagai kawasan yang memiliki iklim yang beragam. Iklim adalah kebiasaan alami yang didorong oleh kombinasi beberapa elemen seperti radiasi matahari, suhu, kelembaban, hujan, suhu udara, tekanan udara, dan tekanan angin.

Hujan adalah fenomena yang merupakan produk dari proses kondensasi uap air atmosfer dan pengaruh banyak faktor laut-atmosfer. Terjadinya peristiwa hujan ekstrem yang terkait dengan variabilitas iklim dapat mengakibatkan banjir dan kekeringan dengan kerusakan material dan bahkan hilangnya nyawa manusia di masyarakat setempat; Oleh karena itu, sangat penting untuk mempelajari variabilitas hujan dalam hal anomali, yang menunjukkan penyimpangan dari pola normal hujan.

Salah satu ayat dalam Al-Quran yang menjelaskan terkait dengan hujan adalah surah Al-Furqan ayat 48-50 yang berbunyi :

وَهُوَ الَّذِي أَرْسَلَ الرِّيحَ بُشْرًا، بَيْنَ يَدَيْ رَحْمَتِهِ ۖ وَأَنْزَلْنَا مِنَ السَّمَاءِ مَاءً طَهُورًا ﴿٤٨﴾ لِّنُخْرِجَ بِهِ ۖ بَلْدَةً مَّيْتًا وَنُسْقِيَهُ ۖ مِمَّا خَلَقْنَا أَنْعَامًا وَأَنَاسِيَّ كَثِيرًا ﴿٤٩﴾ وَلَقَدْ صَرَّفْنَاهُ بَيْنَهُمْ لِيَذَّكَّرُوا فَأَلَّىٰ أَكْثَرُ النَّاسِ إِلَّا كُفُورًا ﴿٥٠﴾

"Dialah yang meniupkan angin (sebagai) pembawa kabar gembira sebelum kedatangan rahmat-Nya (hujan). Kami turunkan dari langit air yang sangat suci.

[48]. Agar dengannya (air itu) Kami menghidupkan negeri yang mati (tandus) dan memberi minum kepada sebagian apa yang telah Kami ciptakan, (berupa) hewan-hewan ternak dan manusia yang banyak [49]. Sungguh, Kami benar-benar telah mempergilirkannya (hujan itu) di antara mereka agar mereka mengambil pelajaran. Akan tetapi, kebanyakan manusia tidak mau (bersyukur), bahkan mereka mengingkari (nikmat) [50]." (Q.S. At-Taubah: 105).

Ayat ini (QS. Al-Furqan: 48-50) tidak hanya menjadi pengingat untuk bersyukur atas nikmat hujan sebagai berkah kehidupan, tetapi juga menegaskan bahwa Allah sengaja 'mempergilirkan' hujan di antara manusia (ayat 50) agar mereka mengambil pelajaran (*ibrah*). Dalam tafsir Al-Misbah, Quraish Shihab menjelaskan bahwa fenomena hujan baik yang membawa rahmat maupun bencana adalah ujian kesadaran manusia untuk mempelajari hukum alam dan mengelola risiko secara bijak (Qutb, 2012a). Hal ini selaras dengan tujuan penelitian ini, di mana ANN digunakan untuk memprediksi hujan sebagai upaya mitigasi bencana, sekaligus bentuk ikhtiar manusia dalam memahami tanda-tanda kebesaran-Nya.

Penggunaan metode *machine learning* seperti *Artificial Neural Network* dapat membantu meningkatkan akurasi dan efektivitas dalam memprediksi hujan. Meskipun metode yang digunakan telah cukup berhasil dalam berbagai prediksi hujan, tetapi penggunaan metode *Artificial Neural Network* untuk prediksi hujan masih memerlukan eksplorasi lebih lanjut, terutama dalam hal bagaimana fitur-fitur yang kompleks. *Mean Absolute Percent Error* (MAPE) menunjukkan tingkat kesalahan absolut dalam prediksi dengan nilai aktual (Nabillah & Ranggadara, 2020).

Penelitian-penelitian terdahulu telah memberikan kontribusi signifikan dalam pengembangan metode prediksi hujan. Namun, masih terdapat beberapa

permasalahan yang perlu diperhatikan. Misalnya, penelitian oleh Lesnussa et al. (2018) implementasi algoritma *Backpropagation* pada *Artificial Neural Network* (ANN) dengan bantuan perangkat lunak MATLAB mampu menghasilkan akurasi prediksi curah hujan sebesar 80%. Meskipun hasil ini cukup baik, penelitian tersebut masih terbatas pada penggunaan parameter *alpha*, *epoch*, dan nilai MSE yang mungkin belum optimal untuk berbagai kondisi geografis dan klimatologis.

Selain itu, penelitian oleh Sharma & Nijhawan (2022) di Delhi, India, menunjukkan bahwa meskipun algoritma *backpropagation* memberikan konsistensi dan akurasi yang baik, nilai *Minimum Square Error* (MSE) yang dihasilkan masih relatif tinggi, yaitu 6,58. Hal ini mengindikasikan bahwa prediksi hujan masih memiliki ruang untuk peningkatan akurasi, terutama dalam menangani data yang fluktuatif atau ekstrem. Penelitian lain oleh Suparta & Samah (2020) yang menggunakan metode *Adaptive Sistem Inferensi Neuro Fuzzy* (ANFIS) juga menunjukkan hasil yang menjanjikan dengan 80% dari data testing diprediksi baik. Namun, penelitian ini menggaris bawahi pentingnya preprocessing data dan karakteristik data yang fluktuatif atau ekstrem, yang dapat mempengaruhi hasil prediksi. Oleh karena itu, diperlukan pendekatan yang lebih komprehensif dalam memilih parameter dan metode yang sesuai untuk meningkatkan akurasi prediksi hujan.

Dengan demikian, tujuan penelitian untuk memberikan informasi lebih dalam pencegahan dan pengembangan kewaspadaan terkait hujan di Indonesia, sehingga dapat mengurangi kerusakan dan meningkatkan kualitas hidup masyarakat. Dalam pandangan agama Islam, upaya ini juga diharapkan sebagai

bagian dari usaha dalam menuntut ilmu dan implementasi demi kemakmuran bersama umat manusia.

1.2. Rumusan Masalah

Berdasarkan pada uraian latar belakang, Bagaimana pengaruh dari *Artificial Neural Network* (ANN) pada pemrosesan data hujan terhadap prediksi hujan.

1.3. Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Sumber data untuk penelitian ini adalah dataset yang berasal dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Dataset ini mencakup informasi hujan yang ada di Indonesia terutama hujan pada Kab. Malang pada periode 2016-2020. Data yang diambil termasuk fitur-fitur seperti temperatur, kelembaban, kecepatan angin, dan lain-lain.
2. Data penelitian yang diambil bersumber dari dataset publik. Tidak dilakukan proses pengumpulan dataset lanjutan oleh penulis.
3. *Artificial Neural Network* diimplementasikan menggunakan bahasa pemrograman *Python*.

1.4. Tujuan Penelitian

Untuk mengetahui dan menganalisis tingkat akurasi *Artificial Neural Network* dalam memprediksi hujan di Kab. Malang.

1.5. Manfaat Penelitian

Dengan melakukan penelitian ini, diharapkan dapat memberikan manfaat kedepannya. Contoh manfaat yang diharapkan termasuk dalam hal-hal berikut:

1. Sumbangan positif bagi wilayah tertentu untuk memberikan informasi tambahan dalam mengambil keputusan preventif berdasarkan hasil prediksi demi upaya pencegahan dampak hujan tinggi.
2. Membuka peluang pengembangan teknologi untuk memprediksi hujan yang lebih maju, dan dapat dijadikan sebuah referensi untuk penelitian setelah ini yang berkaitan dengan hujan pada daerah lainnya.

BAB II

STUDI PUSTAKA

2.1. Penelitian Terkait

Beberapa penelitian terdahulu telah mengkaji prediksi curah hujan, salah satunya studi yang dilakukan oleh Lesnussa, Mustamu, Kondo Lembang, dan Talakua (Lesnussa et al., 2018). Dalam penelitian tersebut, metode *Backpropagation* pada Jaringan Saraf Tiruan (JST) diimplementasikan menggunakan perangkat lunak MATLAB, menghasilkan akurasi prediksi sebesar 80%. Parameter yang digunakan meliputi learning rate 0.7, *epoch* 10.000, dan nilai *Mean Squared Error* (MSE) sebesar 0.022.

Prediksi hujan dilakukan oleh Sharma & Nijhawan (Ankita & Geeta, 2022) penelitian ini dilakukan di Delhi, India dengan menggunakan data meteorologi dari bulan Mei hingga September. Proses analisis meliputi perhitungan pada data *training* dan *testing*, serta identifikasi jaringan *neuron* tersembunyi menggunakan tiga algoritma berbeda. Pada arsitektur *multilayer*, dilakukan pengujian terhadap tiga algoritma yaitu *backpropagation*, *cascaded backpropagation*, dan *layer recurrent network*. Hasil penelitian menunjukkan bahwa arsitektur *multilayer* dengan algoritma *backpropagation* memberikan konsistensi dan akurasi yang lebih baik dibandingkan algoritma lainnya, dengan nilai *Mean Squared Error* (MSE) sebesar 6,58. Kinerja optimal tercapai pada *epoch* ke-15.

Penelitian Suparta & Samah (Suparta & Samah, 2020) menerapkan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) yang mengintegrasikan

kemampuan pembelajaran jaringan saraf tiruan dengan sistem logika *fuzzy* untuk prediksi curah hujan. Hasil evaluasi selama enam tahun menunjukkan performa model yang cukup baik dengan akurasi prediksi mencapai 80% pada data testing. Kualitas prediksi sangat bergantung pada kelengkapan dan konsistensi format data, sehingga tahap *preprocessing* data menjadi krusial. Selain itu, karakteristik data yang bersifat fluktuatif atau ekstrem dapat menurunkan akurasi prediksi. Untuk pengembangan selanjutnya, diperlukan incorporasi parameter-parameter meteorologis yang memiliki korelasi kuat dengan curah hujan seperti suhu permukaan, kelembaban relatif, dan kecepatan angin.

2.2. Hujan

Hujan adalah jumlah air hujan yang jatuh ke permukaan bumi dalam satuan waktu tertentu, biasanya diukur dalam milimeter (mm). hujan merupakan salah satu parameter cuaca yang sangat penting karena berpengaruh langsung terhadap kehidupan manusia, seperti ketersediaan air, pertanian, dan pengelolaan sumber daya alam. hujan ini diukur harian, setiap bulanan dan tahunan dalam milimeter atau sentimeter. Faktor-faktor seperti: topografi, arah kemiringan medan, arah angin, dan kecepatan angin dapat mempengaruhi hujan (Mukid & Sugito, 2013).

Hujan dapat diklasifikasikan berdasarkan intensitasnya menjadi empat kategori, yaitu hujan ringan (0-5 mm/hari), hujan sedang (5-20 mm/hari), hujan lebat (20-50 mm/hari), dan hujan sangat lebat (>50 mm/hari) (Gede et al., 2022). Klasifikasi ini digunakan untuk memantau dan memprediksi potensi dampak hujan, seperti banjir atau tanah longsor. hujan dipengaruhi oleh berbagai faktor, baik lokal maupun global. Faktor lokal meliputi suhu udara, kelembaban, tekanan udara, dan

topografi wilayah.

Sementara itu, faktor global seperti fenomena *El Niño* dan *La Niña* juga memiliki dampak signifikan terhadap pola hujan di suatu wilayah. (Iskandar et al., 2019) menjelaskan bahwa *El Niño* cenderung mengurangi hujan di Indonesia, sedangkan *La Niña* meningkatkan intensitas hujan. Selain itu, perubahan iklim global juga memengaruhi pola hujan, menyebabkan terjadinya anomali cuaca seperti musim hujan yang lebih panjang atau lebih pendek dari biasanya. Hal ini menuntut adanya sistem prediksi hujan yang akurat untuk mengantisipasi dampaknya, seperti banjir atau kekeringan.

2.3. *Machine Learning*

Machine Learning (ML) merupakan cabang ilmu dalam bidang kecerdasan buatan (*Artificial Intelligence/AI*) yang khusus mempelajari pengembangan model komputasi dan algoritma, dimana sistem komputer mampu belajar secara mandiri dari pengalaman untuk meningkatkan performanya dalam menyelesaikan berbagai tugas tanpa memerlukan pemrograman secara langsung. (Ibnu Daqiqil Id, 2020). Berbeda dengan pendekatan pemrograman tradisional yang mengandalkan penulisan aturan dan instruksi secara eksplisit, *machine learning* memanfaatkan data untuk mengidentifikasi pola dan korelasi. Metode ini memungkinkan sistem komputer melakukan prediksi, pengenalan pola, maupun penyelesaian masalah tanpa memerlukan pemrograman khusus untuk setiap skenario. Esensi fundamental machine learning terletak pada pengembangan algoritma yang mampu belajar secara mandiri dari data serta menghasilkan prediksi atau pengambilan keputusan berbasis data..

Machine learning telah mendapatkan adopsi yang luas dan telah merevolusi berbagai industri, termasuk kesehatan, keuangan, transportasi, pemasaran, dan lain-lain. Pengembangan di bidang ini terus aktif, dengan algoritma dan teknik baru terus dikembangkan untuk meningkatkan kinerja dan mengatasi berbagai tantangan.

2.4. *Artificial Neural Network*

Artificial Neural Network (ANN) merupakan model komputasi yang meniru bagaimana fungsi neuron alami dapat digunakan untuk menyelesaikan berbagai macam masalah. Pada model ini, setiap unit neuron akan teraktivasi ketika menerima masukan tertentu, kemudian meneruskan sinyal yang berpotensi mengaktifkan neuron berikutnya. Proses aktivasi neuron dihitung melalui penerapan fungsi matematika terhadap jumlah tertimbang dari seluruh masukan. Nilai bobot koneksi antar neuron memegang peranan krusial dalam komputasi ini. Dengan melakukan penyesuaian terhadap nilai bobot tersebut, sistem dapat menghasilkan keluaran yang sesuai untuk setiap masukan yang diberikan (Gershenson, 2009).

Jaringan Saraf Tiruan (JST) memiliki beragam aplikasi dalam berbagai bidang, meliputi: klasifikasi pola, sintesis dan pengenalan suara untuk antarmuka adaptif manusia-komputer, aproksimasi fungsi, kompresi data *visual*, memori asosiatif, analisis klaster, peramalan berbasis data, optimasi kombinatorial, pemodelan sistem nonlinier, serta sistem kendali cerdas. Meskipun menggunakan terminologi biologis, implementasi JST sebenarnya tidak sepenuhnya merepresentasikan proses saraf atau kognitif alami secara presisi. Secara fundamental, JST lebih tepat dipandang sebagai perluasan dari model matematika

dan statistik konvensional, mencakup pengklasifikasi pola nonparametrik, algoritma klasterisasi, filter *nonlinier*, dan berbagai teknik regresi statistik (Montesinos López et al., 2022).


2.4.1. Struktur ANN

Artificial Neural Network (ANN) atau Jaringan saraf tiruan merupakan sistem komputasi yang dirancang khusus untuk identifikasi pola dalam sekumpulan data. Model komputasi ini terinspirasi dari struktur dasar jaringan saraf biologis pada otak manusia, yang mampu melakukan proses pembelajaran dan adaptasi terhadap masukan eksternal. Ketika dipaparkan pada data pelatihan, sistem ini memiliki kapabilitas untuk menemukan korelasi tersembunyi serta mempelajari pemetaan *non-linear* yang kompleks antar variabel data (Back et al., 1998).

Menurut (Simon Haykin, 2005), *Artificial Neural Networks* memiliki beberapa macam arsitektur yang digunakan, sebagai berikut:

1. *Single Layer Network*


Pada arsitektur jaringan ini, terdapat suatu lapisan tertentu yang memiliki konfigurasi bobot koneksi optimal. Mekanisme kerjanya meliputi: (1) *unit input* yang akan teraktivasi ketika menerima sinyal eksternal, dan (2) *unit output* yang berfungsi untuk menghasilkan respons jaringan. Secara struktural, setiap unit input terhubung secara penuh (*fully connected*) dengan semua unit output, namun tidak memiliki koneksi lateral antar unit input dalam lapisan yang sama. Struktur dari *Single Layer Network* ditunjukkan dalam Gambar 2.1.



Gambar 2. 1. *Single Layer Network* (Sumber: Simon Haykin, 2005)

2. *Multilayer Network*

Multilayer network merupakan arsitektur jaringan saraf tiruan yang terdiri atas beberapa lapisan neuron tersembunyi (*hidden layer*) yang terletak di antara lapisan input dan output. Karakteristik utama jaringan ini meliputi: (1) struktur berlapis hierarkis, dan (2) penggunaan bobot koneksi yang menghubungkan *neuron* antar lapisan, termasuk lapisan input, hidden layer, dan lapisan output seperti yang terlihat pada Gambar 2.2.



Gambar 2. 2. *Multilayer Network* (Sumber: Simon Haykin, 2005)


Pada saat melatih jaringan *multilayer* mungkin akan lebih sulit dibandingkan dengan melatih *single layer* namun jaringan *multilayer* mampu memecahkan masalah yang lebih kompleks daripada jaringan *single layer*. Dalam beberapa kasus, pelatihan mungkin lebih berhasil dengan menggunakan Jaringan *multilayer*, karena jaringan *multilayer* lebih mampu menyelesaikan masalah yang tidak dapat diselesaikan oleh jaringan *single layer*.

BAB III

METODOLOGI DAN DESAIN PENELITIAN

3.1. Desain Penelitian

Pada bab ini, ada beberapa tahapan yang digunakan dalam penelitian ini untuk memudahkan penulis dalam menentukan langkah selanjutnya sehingga mendapatkan hasil yang diharapkan. Diagram blok desain penelitian ditunjukkan pada gambar 3.1 berikut.



Gambar 3. 1. Desain Penelitian

Sebuah tahap awal dalam penelitian ini dilakukan dengan studi literatur, yaitu belajar, mencari, dan melengkapi teori-teori dari penelitian sebelumnya mengenai *Artificial Neural Network* (ANN), prediksi hujan, hingga perhitungan hujan yang dapat ditemukan atau dicari mulai dari *e-book* ataupun jurnal terkait.

Tahap selanjutnya adalah desain penelitian dengan melakukan persiapan dan perancangan tahapan-tahapan yang dilakukan untuk mempermudah penulisan. Tahap ketiga yaitu pengumpulan data melalui website terkait, data-data yang sudah terkumpul nantinya akan dipilah dan dipilih sesuai dengan kebutuhan dan nantinya akan diolah pada tahap selanjutnya. Selanjutnya data yang sudah dikumpulkan nantinya akan diolah dan diuji dengan tujuan untuk dapat melihat apakah hasil pengujian sesuai atau tidak sesuai dari yang diharapkan. Tahapan terakhir yaitu analisa hasil, jika data yang dihasilkan dan sudah diproses dengan algoritma sesuai dengan yang diharapkan selanjutnya akan diambil kesimpulan dan menuliskannya pada laporan hasil.

3.2. Pengumpulan Data

Proses pengumpulan data merupakan langkah awal dalam menjalankan penelitian ini. Data yang digunakan dalam penelitian ini berasal dari *dataset Climate Data Daily IDN*. *Dataset Climate Data Daily IDN* diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) dan tersedia secara bebas melalui platform *Kaggle* <https://www.kaggle.com/datasets/greegtitan/indonesia-climate>. Dataset ini memiliki catatan hujan dalam kurun waktu 2 tahun di Indonesia mulai dari tahun 2018-2019 meliputi berbagai variabel yang berkaitan dengan hujan. Contoh dataset *Climate Data Daily IDN* adalah sebagai berikut.

Tabel 3. 1. *Dataset Climate Data Daily IDN*

<i>Station id</i>	<i>Min Temp er (°C)</i>	<i>Max Temp er (°C)</i>	<i>Avg Tempe r (°C)</i>	<i>Avg Humi d (%)</i>	<i>Rainf all (mm)</i>	<i>Durati on of Sunshi ne (hour)</i>	<i>Max Wind Speed (m/s)</i>	<i>Wind Directio n at Maximu m Speed</i>	<i>Avg Wind Speed</i>
96943	21.0	29.2	24.1	86.0	6.0	4.2	3.0	18.00	1.0
96943	21.0	30.0	24.9	81.0	3.4	6.1	4.0	18.00	2.0
96943	22.0	30.3	25.4	78.0	0	4.8	4.0	18.00	0
96943	22.0	28.7	24.8	85.0	1.0	6.1	5.0	18.00	2.0
96943	22.0	30.0	23.5	85.0	0	6.0	8.0	4.00	2.0
96943	21.0	29.0	24.0	83.0	3.9	3.5	2.0	18.00	1.0
96943	20.0	27.3	23.9	84.0	9.0	5.0	3.0	18.00	0
96943	21.0	27.4	23.7	84.0	0	9.0	4.0	4.00	1.0
96943	21.0	26.4	22.7	83.0	4.0	2.7	4.0	9.00	2.0
96943	21.0	27.6	23.6	90.0	31.0	2.5	3.0	18.00	1.0

Dataset Climate Data Daily IDN mencakup beberapa atribut seperti temperatur, kelembaban, hujan, durasi cahaya matahari, kecepatan angin, arah angin dominan, dan atribut lainnya. Berikut adalah penjelasan tentang semua atribut/kolom dalam *dataset Climate Data Daily IDN*:

1. *Min Temperature*: Temperatur terendah.
2. *Max Temperature*: Temperatur maksimal.
3. *Avg Temperature*: Temperatur rata-rata.
4. *Avg Humidity*: Kelembaban rata-rata.
5. *Rainfall*: hujan.
6. *Duration of Sunshine*: Durasi cahaya matahari.
7. *Max Wind Speed*: Kecepatan maksimal angin.
8. *Wind Direction at Maximum Speed*: Arah angin pada kecepatan maksimal.
9. *Avg Wind Speed*: Kecepatan angin rata-rata.

10. *Most Wind Direction*: Arah angin dominan.
11. *Station id*: Kode stasiun yang menyimpan data.

3.3. *Preprocessing Data*

Sebelum proses pelatihan *Artificial Neural Network* (ANN) dilakukan, tahap *preprocessing* data merupakan langkah krusial yang harus dilaksanakan. Teknik-teknik *preprocessing* berperan penting dalam meningkatkan kualitas dataset, yang secara signifikan dapat memengaruhi peningkatan akurasi model dan optimalisasi efisiensi proses data *mining*. Dalam konteks *knowledge discovery*, *preprocessing* data menempati posisi vital mengingat kualitas hasil analisis sangat bergantung pada kualitas data yang digunakan sebagai input (Merdekawati & Ismail, 2019). Tahap *preprocessing* meliputi serangkaian prosedur penting, antara lain: penanganan data yang hilang (*missing values*), konversi tipe data apabila diperlukan, serta seleksi fitur yang relevan untuk keperluan pelatihan model. Langkah-langkah ini secara kolektif berperan dalam mempersiapkan data yang optimal sebelum proses pemodelan (Pebdika et al., 2023). *Preprocessing* data bertujuan untuk memastikan kualitas data yang baik dan menghindari bias dalam hasil prediksi.

Salah satu permasalahan yang relevan dalam konteks kualitas data adalah keberadaan data yang hilang (*missing value*). Data yang tidak lengkap bisa berasal dari berbagai sumber seperti catatan tentang hujan, rusaknya peralatan, dan lain sebagainya.

3.4. Normalisasi Data

Normalisasi data merupakan teknik transformasi nilai input dari berbagai rentang skala menjadi satuan ukuran yang terstandarisasi. Proses ini memiliki dua tujuan utama: mempercepat laju konvergensi selama pelatihan, dan meningkatkan akurasi model jaringan saraf tiruan. Dalam konteks ANN, fungsi aktivasi *sigmoid* yang menghasilkan nilai output dalam interval $[0,1]$ menjadi pertimbangan penting perlunya normalisasi input ke rentang serupa. *Min-max normalization* muncul sebagai metode yang umum diterapkan, dimana teknik ini melakukan transformasi *linear* terhadap data *input* ke dalam *range* $[0,1]$ melalui persamaan matematis tertentu (Vanneschi & Castelli, 2018):

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

x_{norm} : Data hasil normalisasi

x : Data *input*

x_{min} : Nilai minimum dari data *input*


x_{max} : Nilai maksimum dari data *input*

Dengan normalisasi data, setiap variabel *input* akan memiliki pengaruh yang sama terhadap *output* yang dihasilkan oleh ANN.

3.5. Flowchart

Sistem yang akan dibuat mengimplementasikan algoritma *backpropagation neural network* yang digambarkan melalui *flowchart* sebagai proses pemecahan masalah (Rachman et al., 2018). *Flowchart* diwakili oleh simbol simbol yang dapat mewakili langkah-langkah penyelesaian dengan simbol. Langkah awal yaitu dengan memasukkan input pada *layer* pertama, Kemudian melakukan fungsi aktivasi dan diteruskan menuju *hidden layer*. Dilakukanlah aktivasi pada *hidden*

layer dan diteruskan menuju *output layer*. Pada *output layer* dilakukanlah aktivasi untuk menghasilkan proses klasifikasi “hujan” atau “tidak hujan”. Apabila *epoch*nya belum maksimal maka kembali ke proses input dan mengulangi seluruh proses. Ditunjukkan pada Gambar 3.2 berikut.



Gambar 3. 2. *Flowchart* tahapan prediksi.

3.6. *Feature Selection*

Feature selection merupakan tahapan krusial dalam analisis data dan *machine learning* yang berfokus pada identifikasi serta seleksi variabel-variabel paling signifikan dari suatu *dataset*. Proses ini memiliki dua tujuan strategis:

reduksi dimensionalitas data, dan peningkatan performa prediktif model. Dalam penelitian prediksi curah hujan, implementasi teknik *feature selection* menjadi esensial untuk mempertahankan hanya parameter-parameter meteorologis yang paling berpengaruh, sehingga dapat menghasilkan model prediksi yang lebih akurat dan efisien.

Salah satu metode *feature selection* yang digunakan adalah *Preference Selection Index* (PSI). *Preference Selection Index* (PSI) adalah salah satu metode yang digunakan untuk mengukur dan mengevaluasi preferensi atau pilihan dalam konteks tertentu (Yudistira, 2022). Metode ini sering digunakan dalam situasi di mana ada banyak faktor yang perlu dipertimbangkan, dan kita perlu menentukan prioritas atau preferensi dari setiap faktor tersebut. PSI bekerja dengan cara memberikan bobot atau nilai pada setiap kriteria, kemudian mengkombinasikan nilai-nilai tersebut untuk menghasilkan peringkat alternatif. Dengan demikian, PSI membantu dalam mengambil keputusan yang lebih objektif dan terstruktur.

3.6.1. Contoh penerapan PSI *Feature Selection*

Proses PSI dimulai dengan mengidentifikasi kriteria-kriteria yang relevan untuk pengambilan keputusan. Setiap kriteria kemudian dinilai berdasarkan seberapa pentingnya dalam konteks keputusan yang akan diambil. Setelah itu, alternatif-alternatif yang ada dievaluasi berdasarkan kriteria tersebut. PSI menggunakan pendekatan matematis untuk menghitung indeks preferensi, yang menggabungkan nilai dari setiap kriteria untuk setiap alternatif. Hasil akhirnya adalah peringkat alternatif berdasarkan indeks preferensi, di mana alternatif dengan indeks tertinggi dianggap sebagai pilihan terbaik.

Tabel 3. 2. Contoh Dataset

No	Suhu (°C)	Kelembaban (%)	Tekanan Udara (hPa)	Kecepatan Angin (km/jam)	Hujan (mm)
1	28	80	1010	10	50
2	30	75	1008	15	40
3	25	85	1012	5	60
4	27	82	1011	8	55

Kita ingin menentukan fitur mana (Suhu, Kelembaban, Tekanan Udara, Kecepatan Angin) yang paling berpengaruh terhadap Hujan menggunakan PSI. Berikut langkah-langkahnya:

1. Normalisasi Data

PSI membutuhkan normalisasi data untuk memastikan semua fitur berada dalam skala yang sama. Kita menggunakan normalisasi min-max:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

Berikut hasil normalisasi:

Tabel 3. 3. Hasil Normalisasi

No	Suhu (°C)	Kelembaban (%)	Tekanan Udara (hPa)	Kecepatan Angin (km/jam)
1	0.6	0.5	0.5	0.5
2	1.0	0.0	0.0	1.0
3	0.0	1.0	1.0	0.0
4	0.4	0.7	0.75	0.3

2. Hitung Nilai Rata-Rata (μ) dan Simpangan Baku (σ) untuk Setiap Fitur

Hitung rata-rata dan simpangan baku dari setiap fitur yang sudah dinormalisasi.

Suhu:

$$\mu = \frac{0.6 + 1.0 + 0.0 + 0.4}{4} = 0.5$$

$$\sigma = \sqrt{\frac{(0.6 - 0.5)^2 + (1.0 - 0.5)^2 + (0.0 - 0.5)^2 + (0.4 - 0.5)^2}{4}} = 0.35$$

Kelembaban:

$$\mu = \frac{0.5+0.0+1.0+0.7}{4} = 0.55$$

$$\sigma = \sqrt{\frac{(0.5-0.55)^2+(0.0-0.55)^2+(1.0-0.55)^2+(0.7-0.55)^2}{4}} = 0.37$$

Tekanan Udara

$$\mu = \frac{0.5+0.0+1.0+0.75}{4} = 0.56$$

$$\sigma = \sqrt{\frac{(0.5-0.56)^2+(0.0-0.56)^2+(1.0-0.56)^2+(0.75-0.56)^2}{4}} = 0.38$$

Kecepatan Angin

$$\mu = \frac{0.5+1.0+0.0+0.3}{4} = 0.45$$

$$\sigma = \sqrt{\frac{(0.5-0.45)^2+(1.0-0.45)^2+(0.0-0.45)^2+(0.3-0.45)^2}{4}} = 0.36$$

3. Hitung *Preference Variation Value* (PV)

PV dihitung menggunakan rumus:

$$PV = \frac{\mu}{\sigma} \quad (3.3)$$

$$\text{Suhu} = PV = \frac{0.35}{0.5} = 0.7$$

$$\text{Kelembaban} = PV = \frac{0.37}{0.55} = 0.67$$

$$\text{Tekanan Udara} = PV = \frac{0.38}{0.56} = 0.68$$

$$\text{Kecepatan Angin} = PV = \frac{0.36}{0.45} = 0.8$$

4. Hitung *Preference Selection Index* (PSI)

PSI dihitung dengan rumus:

$$PSI = 1 - PV \quad (3.4)$$

$$\text{Suhu} = PSI = 1 - 0.7 = 0.3$$

$$\text{Kelembaban} = PSI = 1 - 0.67 = 0.33$$

$$\text{Tekanan Udara} = PSI = 1 - 0.68 = 0.32$$

$$\text{Kecepatan Angin} = PSI = 1 - 0.8 = 0.2$$

5. Rangking fitur berdasarkan PSI

Semakin tinggi nilai PSI, semakin penting fitur tersebut.

Kelembaban (PSI = 0.33)

Tekanan Udara (PSI = 0.32)

Suhu (PSI = 0.3)

Kecepatan Angin (PSI = 0.2)

Berdasarkan perhitungan PSI, fitur Kelembaban dan Tekanan Udara adalah yang paling penting untuk prediksi hujan, sedangkan Kecepatan Angin adalah yang paling tidak penting. Dengan demikian, kita dapat memprioritaskan fitur-fitur seperti rata-rata kelembaban, rata-rata suhu, durasi sinar matahari, curah hujan, rata-rata kecepatan angin dalam membangun model prediksi hujan.

3.7. Skenario Uji

Skenario uji pada penelitian ini bertujuan untuk mengevaluasi performa dari *Artificial Neural Network* pada klasifikasi dan prediksi hujan. Pengujian nantinya dilakukan dengan menggunakan data *testing* yang sudah dipisahkan dengan data *training*. Skenario pengujian digunakan untuk pengukuran seberapa baik model yang sudah diterapkan dalam prediksi dan klasifikasi hujan berdasarkan data yang sudah ada. Pada penelitian ini model *Artificial Neural Network* memiliki 3 lapisan *First Layer*, *Hidden Layer*, *Output layer*. Pada *layer* pertama akan menerima 5 fitur *input* dari Tnavg, RHavg, RR, ss, favg, *input* pada *layer* pertama ini akan dihitung

menggunakan 4 neuron dan menghasilkan 4 *output*, *output* dari layer pertama kemudian akan diteruskan kepada *hidden layer* kedua yang terdapat 3 neuron kemudian dihitung dan menghasilkan 3 *output*, yang terakhir *output layer* terdapat 1 *neuron* didalamnya yang menerima *input* dari *hidden layer* dan pada bagian ini nantinya ditentukan hasil akhir apakah data interpretasi berupa hujan atau tidak hujan. Evaluasi model menggunakan *Confusion Matrix*.

3.7.1. *Confusion Matrix*

Confusion matrix. *Confusion matrix* adalah sebuah tabel yang digunakan untuk mengevaluasi kinerja algoritma klasifikasi. *Confusion matrix* menunjukkan perbandingan antara nilai sebenarnya (*ground truth*) dan hasil prediksi dari model klasifikasi. *Confusion matrix* memiliki 4 komponen utama berupa *True Positives* (TP), *False Positives* (FP), *True Negatives* (TN), dan *False Negatives* (FN). *Confusion matrix* memiliki 5 metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *f1-score*. *Accuracy* adalah metrik evaluasi yang mengukur seberapa baik model membuat prediksi yang benar dari total prediksi yang dilakukan. *Precision* adalah metrik evaluasi yang mengukur seberapa baik model membuat prediksi yang benar untuk kelas positif dari total prediksi positif yang dilakukan. *Recall* adalah metrik evaluasi yang menggambarkan seberapa baik suatu model dalam mengidentifikasi kelas positif dengan benar. *F1 Score* merupakan metrik evaluasi yang mencerminkan keseimbangan antara *Precision* dan *Recall*. Berikut rumus dari metrik evaluasi tersebut.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (3.5)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3.6)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3.7)$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (3.8)$$

Keterangan

TP = prediksi positif dan benar

TN = prediksi negatif dan benar

FP = prediksi positif dan salah

FN = prediksi negatif dan salah

BAB IV

HASIL DAN PEMBAHASAN

Bab ini menjelaskan terkait dengan hasil dan pembahasan untuk prediksi hujan menggunakan *Artificial Neural Network*. Hasil pengujian diambil dari empat hasil *learning rate* berbeda yang akan menghasilkan beberapa hasil untuk prediksi hujan di Kab. Malang. Menurut (Nuzly Abdull Hamed et al., 2008) nilai *learning rate* berada pada rentan 0 sampai 1, tidak ada metode baku dalam penentuan *learning rate*.

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.

4.1. Implementasi Sistem

Sistem ini diimplementasikan dengan *Python* dan *Google Colab* melalui beberapa langkah utama yang dirancang untuk mendukung pembuatan model prediksi hujan berbasis *Artificial Neural Network* (ANN). Setiap tahap disusun secara sistematis guna memastikan pengolahan data yang efektif serta menghasilkan model yang optimal. Proses implementasinya mencakup tahapan-tahapan berikut:

1. *Import Library dan Load Dataset*

Library digunakan untuk melakukan komputasi sistem yang diperlukan untuk pengolahan data lebih lanjut sesuai dengan kebutuhan. Pustaka mencakup modul bawaan *python* dan modul pihak ketiga seperti *pandas*, *matplotlib*, dan *scikit-learn*. Pemanfaatan modul pustaka tersebut untuk memudahkan dalam pengerjaan sistem. Proses selanjutnya difokuskan pada akses dan *load dataset* dari *Google Drive* menggunakan fitur autentikasi dari *Google Colab* sehingga nantinya *dataset* dapat langsung digunakan tanpa harus membuka *Google Drive* terlebih dahulu. Data yang dimasukkan merupakan *dataset* dengan format (xlsx) yang didapat dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) pada kurun waktu 2018-2019 pada wilayah Kab. Malang yang memiliki total data sebanyak 730 data.

2. *Preprocessing Data*

Tahap *preprocessing data* dilakukan untuk mempersiapkan data mentah agar memenuhi kriteria kelayakan dalam proses klasifikasi. Langkah pertama yang dilaksanakan adalah pengecekan nilai kosong (*missing values*) pada seluruh atribut dataset. Hasil analisis menunjukkan bahwa tidak terdapat *missing values* pada kolom-kolom yang diteliti, sehingga tidak diperlukan tindakan imputasi atau penghapusan data. Selanjutnya, dilakukan seleksi fitur (*feature selection*) untuk menentukan variabel prediktor yang signifikan. Fitur yang terpilih adalah Tavg (temperatur rata-rata dalam °C), Rhavg (rata-rata kelembaban dalam %), RR (curah hujan dalam mm), ss (durasi sinar matahari dalam jam), dan ffavg (rata-rata

kecepatan angin dalam m/s).

Sebelum diproses data juga akan dinormalisasi untuk mengubah data ke rentan tertentu agar variabel memiliki skala yang serupa. Pada sistem ini data dinormalisasi menggunakan *Min-Max Scaling* pada rentang 0.1 hingga 0.9.

```
FOR column_index FROM 1 TO 4 DO
  GET current_column = df[:, column_index]
  CALCULATE column_min = MIN(current_column)
  CALCULATE column_max = MAX(current_column)

  SET normalized_values = (0.8 * (current_column -
    column_min)) / (column_max - column_min) + 0.1

  SET df[:, column_index] = normalized_values
END FOR
```

Gambar 4. 1. Normalisasi

3. Membagi Dataset

Hasil analisis evaluasi menunjukkan adanya korelasi positif antara besaran proporsi data latih dengan kualitas performa model. Secara spesifik, dataset penelitian yang terdiri dari 730 data dibagi dengan komposisi 80:20, dimana 80% dialokasikan sebagai data pelatihan (*training set*) dan 20% sebagai data pengujian (*testing set*), sehingga didapatkan 584 *data training* dan 146 data tes.

```
IMPORT train_test_split FROM sklearn.model_selection

state
SET x_train, x_test, y_train, y_test TO train_test_split(
  INPUT_FEATURES = X,
  TARGET_VALUES = Y,
  TEST_SIZE = 0.2,
  RANDOM_STATE = 0
)
```

Gambar 4. 2. Membagi Data *Training* dan Tes

4. Penerapan Model Neural Network

Penerapan arsitektur dasar sebuah jaringan saraf tiruan *Artificial Neural*

Network menggunakan *TensorFlow/Keras* yang memberikan keseimbangan antara kemudahan penggunaan dan fleksibilitas untuk kasus klasifikasi cuaca. Membuat model *sequential* (linier berlapis) dimana aliran data hanya bergerak maju (*feedforward*) dari *input* ke *output*.

```
SET model TO NEW Sequential()
model

ADD Dense LAYER TO model WITH:
  UNITS = 4
  ACTIVATION = 'sigmoid'
  USE_BIAS = True
  NAME = 'FirstLayer'

ADD Dense LAYER TO model WITH:
  UNITS = 3
  ACTIVATION = 'sigmoid'
  USE_BIAS = True

ADD Dense LAYER TO model WITH:
  UNITS = 1
  ACTIVATION = 'sigmoid'
  USE_BIAS = True
  NAME = 'LastLayer'
```

Gambar 4. 3. Model *Neural Network*

Pada *layer* pertama akan menerima 5 fitur *input* dari *Tnavg*, *RHavg*, *RR*, *ss*, *ffavg*, *input* pada *layer* pertama ini akan dihitung menggunakan 4 neuron, hasil perhitungan bobot dan bias dari *layer* pertama kemudian akan diteruskan kepada *hidden layer* kedua yang terdapat 3 neuron dan hasilnya akan diteruskan ke *output layer*, pada lapisan terakhir *output layer* terdapat 1 neuron didalamnya pada bagian ini nantinya ditentukan hasil akhir apakah data interpretasi berupa “hujan” atau “tidak hujan”. Model *neural network* kemudian akan ditentukan cara model belajarnya. Mengontrol *learning rate* selama pelatihan menggunakan Adam (*Adaptive Moment Estimation*), *loss function*: *Mean Squared Error* (MSE) Mengukur rata-rata kuadrat selisih antara prediksi dan nilai sebenarnya, dan *metrics*

hanya untuk monitoring.

```
SET optimizer TO NEW Adam(LEARNING_RATE = 0.01)

COMPILE model WITH:
  OPTIMIZER = optimizer
  LOSS_FUNCTION = 'mean_squared_error'
  METRICS = ['mean_squared_error']
```

Gambar 4. 4. *Learning rate*

5. *Training Model*

Proses pembelajaran model *Artificial neural network* dilakukan dengan memanfaatkan 584 *data training* yang telah disiapkan. Proses training dilakukan selama 125 *epoch* (1 *epoch* = satu siklus lengkap dimana model melihat seluruh data training.) dengan *validation split* sebesar 10% untuk memantau performa model selama pelatihan.

```
SET training_history TO model.fit(
  TRAINING_DATA = x_train_split,
  TARGET_LABELS = y_train,
  EPOCHS = 125,
  VALIDATION_SPLIT = 0.1
)

START TRAINING PROCESS:
  INPUT DATA: x_train_split
  TARGET VALUES: y_train
  TRAINING PARAMETERS:
    NUMBER OF EPOCHS: 125
    VALIDATION SET: 10% of training data
  OUTPUT: training_history (contains metrics over epochs)
```

Gambar 4. 5. *Training Model*

Setelah melalui tahap pelatihan, model kemudian dievaluasi menggunakan data uji yang belum pernah digunakan selama proses training. Evaluasi ini bertujuan untuk mendeteksi masalah jika *Test accuracy* yang jauh lebih rendah dibanding *training accuracy* → mengindikasikan terjadinya *overfitting* (kondisi

ketika model *machine learning* menunjukkan performa sangat baik pada data latih tetapi gagal melakukan generalisasi pada data baru).

```
SET Score TO model.evaluate(
  TEST_DATA = x_test_split,
  TEST_LABELS = y_test,
  VERBOSE = 0 // No progress output
)
PRINT 'Test loss MSE: ' + Score[0]
```

Gambar 4. 6. *Evaluasi Model*

6. Klasifikasi dan Evaluasi

Model yang telah melalui proses pelatihan selanjutnya digunakan untuk membuat prediksi pada data test (*x_test_split*), kemudian hasil prediksi tersebut dibandingkan dengan nilai sebenarnya (*y_test*) untuk mengukur performa model.

```
SET y_pred TO model.PREDICT(INPUT_DATA = x_test_split)
```

Gambar 4. 7. *Prediksi*

```
FOR EACH prediction IN y_pred DO:
  IF prediction > 0.5 THEN:
    SET prediction TO 1
  ELSE:
    SET prediction TO 0
  END IF
END FOR
```


Gambar 4. 8. *Konversi*

Mengkonversi probabilitas menjadi kelas (0 atau 1) dengan *threshold* 0.5. Jika probabilitas $> 0.5 \rightarrow$ diklasifikasikan sebagai 1 ("Hujan"), Jika $\leq 0.5 \rightarrow$ 0 ("Tidak Hujan").

4.2. Hasil uji coba

1. Hasil pengujian model pertama

Pengujian model pertama menggunakan *learning rate* sebesar 0,01 menggunakan 5 *input* yaitu rata-rata suhu, rata-rata kelembaban, hujan, durasi sinar matahari, dan rata-rata kecepatan angin. Hasil pengujian ditunjukkan pada Lampiran 1.



Gambar 4. 9. Hasil pengujian model pertama

Hasil pengujian Model Pertama, terdapat 119 kasus tidak hujan yang benar diprediksi sebagai tidak hujan oleh sistem dan 24 kasus hujan yang benar diprediksi sebagai hujan. Jika dibandingkan dengan data *real*, terdapat 3 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data *real*. Sehingga nilai TP, TN, FP, dan FN dapat dihitung pada tabel 4.1.

Tabel 4. 1. Hasil *Confusion Matrix* model pertama

	<i>Negative</i>	<i>True</i>
<i>True</i>	119 <i>True Negatives</i>	0 <i>False Positives</i>
<i>Negative</i>	3 <i>False Negatives</i>	24 <i>True Positives</i>


Berdasarkan hasil tabel 4.1, maka dapat dihitung evaluasinya menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

$$\begin{aligned}
Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
&= \frac{24 + 119}{24 + 119 + 0 + 3} \times 100\% = 97,95\% \\
Precision &= \frac{TP}{TP + FP} \times 100\% \\
&= \frac{24}{24 + 0} \times 100\% = 100\% \\
Recall &= \frac{TP}{TP + FN} \times 100\% \\
&= \frac{24}{24 + 3} \times 100\% = 88,89\% \\
F1 Score &= \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \\
&= \frac{2 \times 100\% \times 88,89\%}{100\% + 88,89\%} \times 100\% \\
&= 94,12\%
\end{aligned}$$

Berdasarkan hasil pengujian tersebut, diperoleh *accuracy* sebesar 97,95%, *precision* sebesar 100%, *recall* sebesar 88,89%, dan *f1-score* sebesar 94,12%.

2. Hasil pengujian model kedua

Pengujian model kedua menggunakan *learning rate* sebesar 0,02 menggunakan 5 input yaitu rata-rata suhu, rata-rata kelembaban, hujan, durasi sinar matahari, dan rata-rata kecepatan angin. Hasil pengujian ditunjukkan pada Lampiran 2.



Gambar 4. 10. Hasil Pengujian Model Kedua

Hasil pengujian Model Kedua, terdapat 115 kasus tidak hujan yang benar diprediksi sebagai tidak hujan oleh sistem dan 27 kasus hujan yang benar diprediksi sebagai hujan. Jika dibandingkan dengan data *real*, terdapat 4 kasus hujan yang salah diprediksi sebagai hujan oleh sistem namun sebenarnya tidak hujan pada data real. Sehingga nilai TP, TN, FP, dan FN dapat dihitung pada tabel 4.2.

Tabel 4. 2. Hasil *Confusion Matrix* model kedua

	<i>Negative</i>	<i>True</i>
<i>Negative</i>	115 <i>True Negatives</i>	4 <i>False Positives</i>
<i>True</i>	0 <i>False Negatives</i>	27 <i>True Positives</i>

Berdasarkan hasil tabel 4.2, maka dapat dihitung evaluasinya menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

$$\begin{aligned}
 Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
 &= \frac{27 + 115}{27 + 115 + 4 + 0} \times 100\% = 97,26\%
 \end{aligned}$$

$$Precision = \frac{TP}{TP + FP} \times 100\%$$

$$= \frac{27}{27 + 4} \times 100\% = 87.10\%$$

$$Recall = \frac{TP}{TP + FN} \times 100\%$$

$$= \frac{27}{27 + 0} \times 100\%$$

$$= 100\%$$


$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\%$$

$$= \frac{2 \times 87,10\% \times 100\%}{87,10\% + 100\%} \times 100\% = 93,10\%$$

Berdasarkan hasil pengujian tersebut, diperoleh *accuracy* sebesar 97,26%, *precision* sebesar 87,10%, *recall* sebesar 100%, dan *f1-score* sebesar 93,10%.

3. Hasil pengujian model ketiga

Pengujian model ketiga menggunakan *learning rate* sebesar 0,04 menggunakan 5 input yaitu rata-rata suhu, rata-rata kelembaban, hujan, durasi sinar matahari, dan rata-rata kecepatan angin. Hasil pengujian ditunjukkan pada Lampiran 3.



Gambar 4. 11. Hasil Pengujian Model Ketiga

Hasil pengujian Model Ketiga, terdapat 119 kasus tidak hujan yang benar diprediksi sebagai tidak hujan oleh sistem dan 26 kasus hujan yang benar diprediksi sebagai hujan. Jika dibandingkan dengan data *real*, terdapat 1 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data *real*. Sehingga nilai TP, TN, FP, dan FN dapat dihitung pada tabel 4.3.

Tabel 4. 3. Hasil *Confusion Matrix* model ketiga

	<i>Negative</i>	<i>True</i>
<i>Negative</i>	119 <i>True Negatives</i>	0 <i>False Positives</i>
<i>True</i>	1 <i>False Negatives</i>	26 <i>True Positives</i>

Berdasarkan hasil tabel 4.3, maka dapat dihitung evaluasinya menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

$$\begin{aligned}
 Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
 &= \frac{26 + 119}{26 + 119 + 0 + 1} \times 100\% \\
 &= 99,32\%
 \end{aligned}$$

$$\begin{aligned}
 Precision &= \frac{TP}{TP + FP} \times 100\% \\
 &= \frac{26}{26 + 0} \times 100\% \\
 &= 100\%
 \end{aligned}$$


$$\begin{aligned}
 Recall &= \frac{TP}{TP + FN} \times 100\% \\
 &= \frac{26}{26 + 1} \times 100\% \\
 &= 96.30\%
 \end{aligned}$$

$$\begin{aligned}
 F1\ Score &= \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \\
 &= \frac{2 \times 100\% \times 96.30\%}{100\% + 96.30\%} \times 100\% \\
 &= 98,11\%
 \end{aligned}$$

Berdasarkan hasil pengujian tersebut, diperoleh *accuracy* sebesar 99,32%, *precision* sebesar 100%, *recall* sebesar 96,30%, dan *f1-score* sebesar 98,11%.

4. Hasil pengujian model keempat

Pengujian model keempat menggunakan *learning rate* sebesar 0,06 menggunakan 5 *input* yaitu rata-rata suhu, rata-rata kelembaban, hujan, durasi sinar matahari, dan rata-rata kecepatan angin. Hasil pengujian ditunjukkan pada Lampiran 4.



Gambar 4. 12. Hasil Pengujian Model Keempat

Hasil pengujian Model keempat, terdapat 119 kasus tidak hujan yang benar diprediksi sebagai tidak hujan oleh sistem dan 21 kasus hujan yang benar diprediksi sebagai hujan. Jika dibandingkan dengan data *real*, terdapat 6 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data *real*. Sehingga nilai TP, TN, FP, dan FN dapat dihitung pada tabel 4.4.

Tabel 4. 4. Hasil *Confusion Matrix* model keempat

	<i>Negative</i>	<i>True</i>
<i>Negative</i>	119 <i>True Negatives</i>	0 <i>False Positives</i>
<i>True</i>	6 <i>False Negatives</i>	21 <i>True Positives</i>

Berdasarkan hasil tabel 4.4, maka dapat dihitung evaluasinya menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

$$\begin{aligned}
 Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \\
 &= \frac{21 + 119}{21 + 119 + 0 + 6} \times 100\% \\
 &= 95,89\%
 \end{aligned}$$

$$\begin{aligned}
 Precision &= \frac{TP}{TP + FP} \times 100\% \\
 &= \frac{21}{21 + 0} \times 100\% = 100\%
 \end{aligned}$$

$$\begin{aligned}
 Recall &= \frac{TP}{TP + FN} \times 100\% \\
 &= \frac{21}{21 + 6} \times 100\% \\
 &= 77,78\%
 \end{aligned}$$

$$\begin{aligned}
 F1 \text{ Score} &= \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \\
 &= \frac{2 \times 100\% \times 77,78\%}{100\% + 77,83\%} \times 100\% \\
 &= 87,50\%
 \end{aligned}$$

Berdasarkan hasil pengujian tersebut, diperoleh *accuracy* sebesar 95,89%, *precision* sebesar 100%, *recall* sebesar 77,78%, dan *f1-score* sebesar 87,50%.

4.3. Pembahasan

Pada studi prediksi hujan menggunakan metode *Artificial Neural Network* didapatkan hasil dari empat model *learning rate* yang berbeda, dari model pertama dengan *learning rate* 0,01, model kedua dengan *learning rate* 0,02, model ketiga dengan *learning rate* 0,04, dan model keempat dengan *learning rate* 0,06. Keempat model ini menggunakan lima *input* yang sama seperti Tnavg (rata-rata suhu), Rhavg (rata-rata kelembaban), RR (hujan), ss (durasi sinar matahari), dan ffavg (rata-rata kecepatan angin). Dari total 730 data yang ada, 146 data diantaranya digunakan sebagai bahan perbandingan antara data pelatihan dan data sebenarnya menghasilkan *output* data “hujan” maupun “tidak hujan”. Setelah 584 data dilakukan pelatihan untuk pembelajaran *neural network*. Selanjutnya 146 data diuji sebagai data tes dalam prediksi hujan.

Hasil pengujian dari keempat model memberikan hasil yang berbeda- beda. Model pertama dari 146 data yang ada, menghasilkan 3 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data real, dengan tingkat akurasi sebesar 97,95%. Pada model kedua dari 146 data yang ada, terdapat 4 kasus hujan yang salah diprediksi sebagai hujan oleh sistem namun sebenarnya tidak hujan pada data *real*, dengan tingkat akurasi 97,26%. Pada model ketiga dari 146 data yang ada, terdapat 1 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data *real*, dengan tingkat akurasi 99,32%. Pada model keempat dari 146 data yang ada, ditemukan 6 kasus hujan yang salah diprediksi sebagai tidak hujan oleh sistem namun sebenarnya hujan pada data *real*, dengan tingkat akurasi 95,89%. Dapat ditelaah bahwa tingkat

akurasi tertinggi didapatkan oleh model ketiga *learning rate* 0,04 dengan tingkat akurasi 99,32%. Perbedaan hasil yang ada dapat disebabkan karena perbedaan *learning rate* yang digunakan, dapat dilihat pada Tabel 4.5.

Tabel 4. 5. Hasil Evaluasi *Artificial Neural Network*

<i>Learning rate</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
0.01	97,95%	100%	88,89%	94,12%
0.02	97,26%	87,10%	100%	93,10%
0.04	99,32%	100%	96,30%	98,11%
0.06	95,89%	100%	77,78%	87,50%

4.4. Integrasi Islam

Islam menempatkan ilmu pengetahuan sebagai bagian integral dari keimanan. Sebagaimana perintah membaca pada Al-Qur'an (*iqra'*) dan mengkaji alam semesta adalah fondasi pengembangan sains. Dalam konteks kekinian, integrasi sains dan Islam menjadi solusi atas dikotomi ilmu yang kerap terjadi. Bab ini menganalisis temuan penelitian melalui lensa Islam dengan tiga pendekatan: (1) teologis (kekuasaan Allah), (2) antropologis (manfaat sosial), dan (3) ekologis (kelestarian alam). Integrasi ini menegaskan bahwa sains dan agama bukanlah dua entitas yang terpisah, melainkan saling melengkapi dalam membangun peradaban yang *rahmatan lil 'alamin*.

4.4.1. *Mu'amalah ma'a Allah*

Dalam perspektif Islam, hujan merupakan manifestasi nyata dari kekuasaan Allah sebagai pengatur alam semesta. QS. Al-Hijr: 22:

وَأَرْسَلْنَا الرِّيحَ لَوَاقِحَ فَأَنْزَلْنَا مِنَ السَّمَاءِ مَاءً فَأَسْقَيْنَاكُمُوهُ وَمَا أَنْتُمْ لَهُ بِخَازِنِينَ ﴿٢٢﴾

“Kami telah meniupkan angin untuk mengawinkan. Maka, Kami menurunkan hujan

dari langit lalu memberimu minum dengan (air) itu, sedangkan kamu bukanlah orang-orang yang menyimpannya.” (QS. Al-Hijr: 22)

Menegaskan bahwa proses hujan - mulai dari angin pembawa awan hingga turunnya air dari langit - sepenuhnya berada di bawah kendali Allah, bukan manusia. Pada Tafsir *Al-Misbah* (Qutb, 2012b) dijelaskan bahwa ayat ini mengingatkan manusia akan keterbatasan pengetahuannya di hadapan sistem alam yang telah Allah tetapkan. Dalam konteks penelitian hujan menggunakan ANN, pendekatan ini menjadi bentuk ikhtiar untuk memahami pola ciptaan-Nya, sekaligus pengakuan bahwa hasil prediksi bersifat nisbi karena hanya Allah yang mengetahui secara mutlak. QS. Luqman: 34:

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنَزِّلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ ﴿٣٤﴾

“Sesungguhnya Allah memiliki pengetahuan tentang hari Kiamat, menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Tidak ada seorang pun yang dapat mengetahui (dengan pasti) apa yang akan dia kerjakan besok. (Begitu pula,) tidak ada seorang pun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Mahateliti.” (QS. Luqman: 34)

Dari Tafsir Ibnu Katsir *Al-Quranul Azhim* (Al-Sheikh, 2003c) dijelaskan bahwa Ini merupakan kunci-kunci keghaiban yang hanya menjadi otoritas ilmu Allah, tidak ada seorang pun yang mengetahuinya kecuali setelah diberitahukan oleh Allah. Pengetahuan tentang waktu hari Kiamat tidak diketahui oleh seorang Nabi yang diutus pun serta tidak pula oleh Malaikat yang terdekat pun. Demikian pula turunnya hujan tidak dapat diketahui kecuali oleh Allah. Akan tetapi, jika Dia memerintahkan-Nya, Dia mengajarkan hal itu kepada para Malaikat yang diberi tugas melaksanakannya dan makhluk-makhluk yang dikehendaki-Nya. Begitu juga

tidak ada yang mengetahui selain-Nya tentang apa yang terdapat di dalam rahim yang Dia kehendaki untuk menciptakannya. Akan tetapi, jika Dia memerintahkan untuk menjadikannya laki-laki, wanita, celaka dan bahagia, maka para Malaikat yang bertugas melaksanakannya dan orang-orang yang dikehendaki-Nya juga dapat mengetahui. Demikian pula tidak ada seseorang yang mengetahui apa yang akan diusahakannya besok di dunianya dan di akhiratnya.

Dengan demikian, adanya metode seperti ANN berfungsi sebagai alat untuk merefleksikan kebesaran Allah melalui kajian ilmiah, bukan sebagai pengganti kekuasaan-Nya.

4.4.2. *Mu'amalah ma'a an-Nas*

Dengan adanya penelitian-penelitian terkait dengan hujan menggunakan ANN merupakan salah satu bentuk implementasi dari prinsip *amar ma'ruf nahi munkar* sebagaimana diperintahkan dalam QS. Al-Maidah: 2.

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَحْلُوا شَعَائِرَ اللَّهِ وَلَا الشَّهْرَ الْحَرَامَ وَلَا الْهَدْيَ وَلَا الْقَلَائِدَ وَلَا آمِينَ الْبَيْتِ الْحَرَامَ يَبْتَغُونَ فَضْلًا مِّن رَّبِّهِمْ وَرِضْوَانًا وَإِذَا حَلَلْتُمْ فَاصْطَادُوا وَلَا يَجْرِمَنَّكُمْ شَنَا نُ قَوْمٍ أَن صَدُّوكُمْ عَنِ الْمَسْجِدِ الْحَرَامِ أَن تَعْتَدُوا وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ ﴿٢﴾

“Wahai orang-orang yang beriman, janganlah kamu melanggar syiar-syiar (kesucian) Allah, jangan (melanggar kehormatan) bulan-bulan haram, jangan (mengganggu) hadyu (hewan-hewan kurban) dan qalā'id (hewan-hewan kurban yang diberi tanda), dan jangan (pula mengganggu) para pengunjung Baitulharam sedangkan mereka mencari karunia dan rida Tuhannya! Apabila kamu telah bertahalul (menyelesaikan ihram), berburulah (jika mau). Janganlah sekali-kali kebencian(-mu) kepada suatu kaum, karena mereka menghalang-halangimu dari Masjidilharam, mendorongmu berbuat melampaui batas (kepada mereka). Tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan permusuhan. Bertakwalah kepada Allah, sesungguhnya Allah sangat berat siksaan-Nya.” (QS. Al-Maidah: 2)

Firman-Nya, “*Tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan permusuhan.*”

Allah Ta'ala memerintahkan hamba-hamba-Nya yang beriman untuk senantiasa tolong-menolong dalam berbuat kebaikan, itulah yang disebut dengan *al-birr* (kebajikan), serta meninggalkan segala bentuk kemungkaran, dan itulah dinamakan dengan *at-taqwa*. Dan Allah melarang mereka tolong-menolong dalam hal kebatilan, berbuat dosa dan mengerjakan hal-hal yang haram. Tafsir Ibnu Katsir *Al-Quranul Azhim* (Al-Sheikh, 2003b).

Banyak hasil penelitian terkait hujan telah memberikan manfaat signifikan bagi kehidupan manusia, tidak hanya dalam mendukung pembangunan berkelanjutan tetapi juga dalam mencegah bencana seperti melalui sistem peringatan dini banjir, optimasi pertanian presisi, dan pencegahan wabah penyakit musim hujan. Sejalan dengan hadis Nabi tentang "sebaik-baik manusia adalah yang paling bermanfaat bagi orang lain" (HR. Ahmad), serta sejalan dengan prinsip *amar ma'ruf nahi munkar*, yakni mengajak kepada kebaikan dan mencegah keburukan. *Amar ma'ruf* pada konteks penelitian ini dapat diwujudkan dengan penyediaan edukasi bagi petani mengenai pola hujan sehingga mereka dapat mengelola lahan dengan lebih baik untuk meningkatkan hasil panen. Sementara itu, *nahi munkar* dapat diterapkan dalam bentuk pencegahan eksploitasi lingkungan yang dapat memperburuk bencana alam, seperti penggundulan hutan yang meningkatkan risiko banjir dan tanah longsor. Dengan demikian, pengembangan teknologi ANN tidak hanya bernilai ilmiah, tetapi juga menjadi media aktualisasi *rahmatan lil 'alamin* melalui pemberdayaan masyarakat.

4.4.3. *Mu'amalah ma'a al-Alam*

Alam termasuk sebagai salah satu rahmat besar yang diberikan kepada manusia dan merupakan sebuah amanah yang wajib dikelola secara bertanggung jawab (QS. Al-A'raf: 56).

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ حَوْفًا وَطَمَعًا إِنَّ رَحْمَتَ اللَّهِ قَرِيبٌ مِّنَ الْمُحْسِنِينَ ﴿٥٦﴾

“Janganlah kamu berbuat kerusakan di bumi setelah diatur dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat dengan orang-orang yang berbuat baik.” (QS. Al-A'raf: 56)

“Janganlah kamu berbuat kerusakan di bumi setelah diatur dengan baik.”

Allah Ta'ala melarang dari melakukan perusakan dan hal-hal yang membahayakannya, setelah dilakukan perbaikan atasnya. Karena jika berbagai macam urusan sudah berjalan dengan baik dan setelah itu terjadi perusakan, maka yang demikian itu lebih berbahaya bagi umat manusia. Maka Allah Ta'ala melarang hal itu, dan memerintahkan hamba-hamba-Nya untuk beribadah, berdo'a dan merendahkan diri kepada-Nya, serta menundukkan diri di hadapan-Nya. Maka Allah pun berfirman *“Dan berdo'alah kepada-Nya dengan rasa takut (tidak akan diterima) dan harapan (akan dikabulkan).”* Maksudnya, takut memperoleh apa yang ada di sisi-Nya berupa siksaan dan berharap pada pahala yang banyak dari sisi-Nya. Kemudian Allah berfirman, *“Sesungguh-nya rahmat Allah amat dekat kepada orang-orang yang berbuat baik.”* Artinya, rahmat-Nya diperuntukkan bagi orang-orang yang berbuat baik yang meng-ikuti berbagai perintah-Nya dan meninggalkan semua larangan-Nya. Tafsir Ibnu Katsir *Al-Qur'an Azhim* (Al-Sheikh, 2003a).

Penelitian-penelitian terkait dengan hujan berbasis ANN menjadi instrumen strategis untuk mewujudkan pelestarian lingkungan yang dapat dilakukan melalui optimalisasi panen air hujan, sistem irigasi presisi, dan pencegahan eksploitasi air tanah. Teknologi ini juga merealisasikan konsep *khalifah fil ardh* (QS. Al-Baqarah: 30) dengan memadukan sains modern dan etika lingkungan dalam Islam. Tidak hanya teknologi yang diuntungkan tetapi juga memberikan manfaat ekologis yang lebih luas kepada alam, seperti pencegahan banjir mulai dari mitigasi bencana dan pencegahan erosi tanah, pengurangan polusi air, pengelolaan air berkelanjutan untuk ekosistem alami flora dan fauna, restorasi lingkungan, adanya reboisasi, dan masih banyak lagi.

Penelitian terkait hujan berbasis ANN bukan sekadar inovasi teknologi, melainkan perwujudan dari tolong-menolong, keseimbangan, dan keagungan Tuhan. Sebagaimana air hujan yang membawa kehidupan, hikmah pelajaran, dan rahmat bagi alam dan manusia. Sebuah ikhtiar kecil untuk mewujudkan misi Islam sebagai agama yang *rahmatan lil 'alamin*.

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, penerapan metode *Artificial Neural Network* pada prediksi hujan terutama pada daerah Malang dapat memberikan klasifikasi yang bersifat objektif dan dapat digunakan sebagai perbandingan pada dataset daerah lain atau sebagai data pengamatan tambahan pola hujan pada periode tertentu. Sistem prediksi hujan yang dibangun mampu berjalan sesuai dengan semestinya berdasarkan hasil uji coba menggunakan *python*. Selain itu, berdasarkan hasil pengukuran akurasi, penilaian sistem memiliki akurasi >90% dari empat *learning rate* yang berbeda. Hasil akurasi ini menunjukkan bahwa prediksi hujan oleh sistem menggunakan *Artificial Neural Network* bersifat baik.

5.2. Saran

Penelitian ini masih memiliki kekurangan yang harus diperbaiki pada penelitian selanjutnya. Penilaian prediksi hujan yang digunakan pada penelitian ini didasarkan dari dataset yang ada pada sistem tanpa mempertimbangkan lingkungan dari daerah itu sendiri. Di dunia nyata, banyak parameter pembeda antara hujan satu dengan yang lain seperti arah mata angin, lokasi, ketinggian dataran, dan sebagainya. Hal tersebut yang menjadi dasar perbedaan antara nilai prediksi hujan satu dengan yang lain. Oleh karena itu, pada penelitian selanjutnya, diharapkan mampu mempertimbangkan parameter-parameter tersebut agar prediksi hujan yang dihasilkan lebih akurat.

DAFTAR PUSTAKA

- Al-Sheikh, D. A. bin M. bin A. bin I. (2003a). Tafsir Ibnu Katsir Al-Qur'an Azhim 3.4 B. Indo.pdf. In *Pustaka Imam AS'syafi'i* (pp. 1–131). https://ia601307.us.archive.org/0/items/Tafsir_Ibnu_Katsir_Lengkap_114Juz/Tafsir_Ibnu_Katsir_3.4.pdf
- Al-Sheikh, D. A. bin M. bin A. bin I. (2003b). Tafsir Ibnu Katsir Al-Quranul Azhim 3.1 B. Indo.pdf. In *Pustaka Imam AS'syafi'i*.
- Al-Sheikh, D. A. bin M. bin A. bin I. (2003c). *Tafsir Ibnu Katsir Al-Quranul Azhim 6.4 B. Indo.pdf* (p. 478). Pustaka Imam AS'syafi'i.
- Ankita, S., & Geeta, N. (2022). Rainfall Prediction Using Artificial Neural Network. *Computational Intelligence-Based Time Series Analysis*, 3(3), 127–141. <https://doi.org/10.29244/j.agromet.31.1.11-21>
- Back, B., Sere, K., & Vanharanta, H. (1998). Managing complexity in large data bases using self-organizing maps. *Accounting, Management and Information Technologies*, 8(4), 191–210. [https://doi.org/10.1016/S0959-8022\(98\)00009-5](https://doi.org/10.1016/S0959-8022(98)00009-5)
- Fausett, L. (1994). Fundamentals of Neural Networks_ Architectures, Algorithms, and Applications. *IEEE Transactions on Computers*, C-18(6), 572. <https://doi.org/10.1109/T-C.1969.222718>
- Gede, I., Gunadi, A., Made, I., Oka Gunawan, A., Widastra, P. E., Candana, H., Ayu, I., Arnawa, W., Agoes Edo, K., & Putra, K. (2022). Klasifikasi Hujan Harian Menggunakan Learning Vector Quantization. *Jurnal Ilmu Komputer Indonesia (JIK)*, 7(2), 1–7.
- Gershenson, C. (2009). *Artificial Neural Networks for Beginners*. 1992. <http://arxiv.org/abs/cs/0308031>
- Ibnu Daqiqil Id. (2020). *MACHINE LEARNING: Teori, Studi Kasus dan Implementasi Menggunakan Python.pdf*. Unri Press. [https://books.google.co.id/books?id=JvBPEAAAQBAJ&lpg=PA1&ots=j--qKFubhp&dq=Machine Learning%3A Teori%2C Studi Kasus dan Implementasi Menggunakan Python \(Vol. 1\). Unri Press&lr&pg=PA1#v=onepage&q&f=false](https://books.google.co.id/books?id=JvBPEAAAQBAJ&lpg=PA1&ots=j--qKFubhp&dq=Machine%20Learning%3A%20Teori%2C%20Studi%20Kasus%20dan%20Implementasi%20Menggunakan%20Python%20(Vol.%201)&pg=PA1#v=onepage&q&f=false)
- Iskandar, I., Lestrai, D. O., & Nur, M. (2019). Impact of El Niño and El Niño Modoki Events on Indonesian Rainfall. *Makara Journal of Science*, 23(4), 217–222. <https://doi.org/10.7454/mss.v23i4.11517>
- Kusmaryanto, S. (2014). Jaringan Saraf Tiruan Backpropagation untuk Pengenalan Wajah Metode Ekstraksi Fitur. *Jurnal EECCIS*, 8(2), 193–198.
- 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>

Merdekawati, G. I., & Ismail. (2019). Prediksi Hujan Di Jakarta Berbasis Algoritma Levenberg Marquardt. *Jurnal Ilmiah Informatika Komputer*, 24(2), 116–128. <https://doi.org/10.35760/ik.2019.v24i2.2366>

Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Multivariate Statistical Machine Learning Methods for Genomic Prediction. In *Multivariate Statistical Machine Learning Methods for Genomic Prediction*. <https://doi.org/10.1007/978-3-030-89010-0>

Mukid, M. A., & Sugito. (2013). Model Prediksi Hujan Dengan Pendekatan Regresi Proses Gaussian. *Media Statistika*, 6(2), 113–122.

Nabillah, I., & Ranggadara, I. (2020). Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut. *JOINS (Journal of Information System)*, 5(2 SE-Articles), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>

Nuzly Abdull Hamed, H., Mariyam Shamsuddin, S., & Salim, N. (2008). Particle Swarm Optimization for Neural Network Learning Particle Swarm Optimization for Neural Network Learning Enhancement. *Jurnal Teknologi*, 49(D), 13–26.

Pebdika, A., Herdiana, R., & Solihudin, D. (2023). Klasifikasi Menggunakan Metode Naive Bayes Untuk Menentukan Calon Penerima Pip. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 452–458. <https://doi.org/10.36040/jati.v7i1.6303>

Qutb, S. (2012a). *Fi Zilalil Quran Al-Furqan.Pdf*. <https://tafsirzilal.wordpress.com/wp-content/uploads/2012/06/al-furqan-indon.pdf>

Qutb, S. (2012b). *Fi Zilalil Quran Al-hijr.pdf*. <https://tafsirzilal.wordpress.com/wp-content/uploads/2012/06/al-hijr-indon.pdf>

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (2019). Learning Representations by Back-Propagating Errors. *Cognitive Modeling*, 2, 213–222. <https://doi.org/10.7551/mitpress/1888.003.0013>

Simon Haykin. (2005). *Neural Networks - A Comprehensive Foundation - Simon Haykin.pdf* (p. 823).

Suparta, W., & Samah, A. A. (2020). Rainfall prediction by using ANFIS times series technique in South Tangerang, Indonesia. *Geodesy and Geodynamics*, 11(6), 411–417. <https://doi.org/10.1016/j.geog.2020.08.001>

Vanneschi, L., & Castelli, M. (2018). Multilayer perceptrons. In *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics* (Vols. 1–3). <https://doi.org/10.1016/B978-0-12-809633-8.20339-7>

Yudistira, A. (2022). Analisa Dalam Pengambilan Keputusan Penentuan Lokasi Usaha Menggunakan Metode Preference Selection Index (PSI). *Jurnal Ilmiah Computer Science*, 1(1), 31–40. <https://doi.org/10.58602/jics.v1i1.4>

LAMPIRAN-LAMPIRAN

Lampiran 1. Hasil Pengujian Model Pertama

Tanggal	Tnavg	RHavg	RR	ss	ffavg	Expected	Got
02/01/2018	0,792	0,842	0,132	0,140	10	1	1
09/01/2018	0,781	0,867	0,100	0,460	0	0	0
11/01/2018	0,792	0,833	0,180	0,404	0	1	1
15/01/2018	0,812	0,800	0,100	0,260	10	0	0
19/01/2018	0,770	0,875	0,219	0,260	10	1	1
28/01/2018	0,842	0,750	0,100	0,500	40	0	0
01/02/2018	0,770	0,833	0,100	0,460	10	0	0
07/02/2018	0,795	0,825	0,127	0,300	10	1	1
10/02/2018	0,795	0,808	0,291	0,100	10	1	1
18/02/2018	0,831	0,800	0,220	0,340	10	1	1
19/02/2018	0,837	0,767	0,100	0,820	10	0	0
20/02/2018	0,814	0,792	0,100	0,660	10	0	0
22/02/2018	0,823	0,808	0,112	0,660	10	0	0
25/02/2018	0,776	0,842	0,182	0,476	0	1	1
06/03/2018	0,831	0,783	0,113	0,380	10	0	0
10/03/2018	0,828	0,783	0,100	0,780	10	0	0
17/03/2018	0,814	0,808	0,100	0,540	10	0	0
18/03/2018	0,792	0,825	0,104	0,500	0	0	0
21/03/2018	0,826	0,758	0,100	0,820	20	0	0
27/03/2018	0,798	0,825	0,100	0,380	10	0	0
14/04/2018	0,856	0,783	0,100	0,780	10	0	0
24/04/2018	0,864	0,742	0,100	0,620	10	0	0
29/04/2018	0,814	0,725	0,100	0,900	10	0	0
03/05/2018	0,790	0,725	0,100	0,900	20	0	0
23/05/2018	0,837	0,792	0,122	0,580	0	1	0
06/06/2018	0,828	0,800	0,100	0,780	0	0	0
07/06/2018	0,806	0,742	0,100	0,460	10	0	0
12/06/2018	0,809	0,767	0,100	0,660	10	0	0
20/06/2018	0,779	0,842	0,154	0,516	10	1	1
22/06/2018	0,779	0,833	0,142	0,140	0	1	1
25/06/2018	0,776	0,775	0,107	0,300	10	0	0
01/07/2018	0,795	0,700	0,100	0,740	0	0	0
07/07/2018	0,746	0,767	0,100	0,780	10	0	0
13/07/2018	0,754	0,767	0,100	0,740	20	0	0
16/07/2018	0,751	0,742	0,100	0,724	10	0	0
22/07/2018	0,820	0,750	0,100	0,500	20	0	0
30/07/2018	0,792	0,742	0,100	0,740	10	0	0
31/07/2018	0,781	0,775	0,100	0,620	10	0	0

03/08/2018	0,723	0,742	0,100	0,100	10	0	0
04/08/2018	0,712	0,750	0,100	0,100	20	0	0
11/08/2018	0,765	0,783	0,100	0,820	20	0	0
25/08/2018	0,743	0,725	0,100	0,884	10	0	0
31/08/2018	0,784	0,758	0,100	0,300	0	0	0
01/09/2018	0,790	0,775	0,100	0,380	10	0	0
05/09/2018	0,773	0,767	0,100	0,460	20	0	0
07/09/2018	0,781	0,767	0,100	0,540	10	0	0
09/09/2018	0,801	0,733	0,100	0,700	10	0	0
10/09/2018	0,823	0,733	0,100	0,860	10	0	0
13/09/2018	0,751	0,742	0,100	0,868	10	0	0
19/09/2018	0,817	0,783	0,100	0,500	0	0	0
21/09/2018	0,837	0,675	0,100	0,420	0	0	0
24/09/2018	0,850	0,700	0,100	0,700	10	0	0
25/09/2018	0,859	0,708	0,100	0,820	10	0	0
26/09/2018	0,842	0,700	0,100	0,860	20	0	0
29/09/2018	0,801	0,725	0,100	0,860	10	0	0
30/09/2018	0,831	0,708	0,100	0,100	10	0	0
07/10/2018	0,839	0,717	0,100	0,580	20	0	0
21/10/2018	0,834	0,742	0,100	0,100	10	0	0
27/10/2018	0,837	0,733	0,100	0,676	10	0	0
29/10/2018	0,820	0,733	0,100	0,740	10	0	0
15/11/2018	0,859	0,758	0,103	0,660	10	0	0
16/11/2018	0,856	0,742	0,100	0,420	10	0	0
27/11/2018	0,814	0,808	0,522	0,300	0	1	1
29/11/2018	0,784	0,858	0,110	0,100	0	0	0
30/11/2018	0,803	0,833	0,226	0,100	10	1	1
13/12/2018	0,853	0,792	0,100	0,460	10	0	0
18/12/2018	0,817	0,783	0,100	0,660	20	0	0
21/12/2018	0,839	0,783	0,418	0,220	10	1	1
23/12/2018	0,809	0,817	0,122	0,180	20	1	0
27/12/2018	0,826	0,783	0,144	0,420	10	1	1
01/01/2019	0,831	0,817	0,123	0,780	10	1	0
02/01/2019	0,820	0,767	0,169	0,260	10	1	1
05/01/2019	0,842	0,783	0,194	0,620	10	1	1
18/01/2019	0,831	0,817	0,305	0,300	10	1	1
22/01/2019	0,792	0,833	0,563	0,100	10	1	1
25/01/2019	0,776	0,867	0,511	0,500	10	1	1
26/01/2019	0,792	0,850	0,340	0,180	10	1	1
28/01/2019	0,861	0,742	0,100	0,700	20	0	0
04/02/2019	0,798	0,842	0,109	0,540	10	0	0

09/02/2019	0,823	0,817	0,100	0,228	0	0	0
11/02/2019	0,856	0,767	0,103	0,540	10	0	0
18/02/2019	0,837	0,800	0,100	0,700	0	0	0
20/02/2019	0,795	0,817	0,152	0,356	0	1	1
24/02/2019	0,814	0,800	0,100	0,620	10	0	0
09/03/2019	0,781	0,783	0,107	0,164	10	0	0
14/03/2019	0,842	0,767	0,100	0,580	10	0	0
20/03/2019	0,814	0,833	0,555	0,340	10	1	1
26/03/2019	0,837	0,825	0,100	0,676	10	0	0
02/04/2019	0,803	0,825	0,100	0,820	10	0	0
03/04/2019	0,812	0,817	0,100	0,620	10	0	0
08/04/2019	0,820	0,833	0,100	0,660	0	0	0
16/04/2019	0,814	0,825	0,135	0,500	10	1	1
21/04/2019	0,850	0,758	0,100	0,420	10	0	0
22/04/2019	0,848	0,750	0,100	0,620	10	0	0
28/04/2019	0,831	0,833	0,100	0,740	20	0	0
29/04/2019	0,814	0,817	0,231	0,500	10	1	1
01/05/2019	0,834	0,800	0,100	0,620	10	0	0
03/05/2019	0,837	0,758	0,100	0,860	10	0	0
11/05/2019	0,809	0,750	0,100	0,780	20	0	0
15/05/2019	0,850	0,750	0,100	0,660	10	0	0
20/05/2019	0,831	0,750	0,100	0,860	20	0	0
27/05/2019	0,831	0,758	0,100	0,500	10	0	0
29/05/2019	0,812	0,783	0,100	0,580	20	0	0
03/06/2019	0,798	0,792	0,100	0,340	20	0	0
06/06/2019	0,828	0,750	0,100	0,564	10	0	0
08/06/2019	0,773	0,783	0,100	0,740	10	0	0
14/06/2019	0,776	0,817	0,109	0,260	20	0	0
16/06/2019	0,806	0,708	0,100	0,820	10	0	0
08/07/2019	0,754	0,742	0,100	0,700	10	0	0
12/07/2019	0,740	0,742	0,100	0,508	10	0	0
21/07/2019	0,773	0,767	0,100	0,420	20	0	0
22/07/2019	0,762	0,742	0,100	0,532	20	0	0
24/07/2019	0,765	0,767	0,100	0,740	20	0	0
27/07/2019	0,790	0,742	0,100	0,740	10	0	0
28/07/2019	0,726	0,783	0,100	0,740	20	0	0
30/07/2019	0,765	0,742	0,100	0,860	20	0	0
31/07/2019	0,729	0,792	0,100	0,836	20	0	0
02/08/2019	0,773	0,750	0,100	0,820	20	0	0
03/08/2019	0,743	0,750	0,100	0,860	20	0	0
04/08/2019	0,726	0,717	0,100	0,780	40	0	0

06/08/2019	0,726	0,700	0,100	0,820	20	0	0
14/08/2019	0,792	0,742	0,100	0,476	10	0	0
20/08/2019	0,770	0,725	0,100	0,892	20	0	0
31/08/2019	0,765	0,733	0,100	0,820	20	0	0
11/09/2019	0,776	0,717	0,100	0,820	20	0	0
16/09/2019	0,787	0,733	0,100	0,740	10	0	0
19/09/2019	0,781	0,717	0,100	0,820	20	0	0
24/09/2019	0,826	0,733	0,100	0,540	10	0	0
25/09/2019	0,837	0,692	0,100	0,788	20	0	0
29/09/2019	0,809	0,742	0,100	0,660	10	0	0
10/10/2019	0,850	0,700	0,100	0,620	10	0	0
11/10/2019	0,870	0,633	0,100	0,780	20	0	0
18/10/2019	0,826	0,700	0,100	0,740	20	0	0
25/10/2019	0,853	0,700	0,100	0,860	10	0	0
26/10/2019	0,864	0,708	0,100	0,740	20	0	0
01/11/2019	0,861	0,717	0,100	0,780	20	0	0
05/11/2019	0,867	0,658	0,100	0,460	10	0	0
06/11/2019	0,823	0,742	0,100	0,780	10	0	0
11/11/2019	0,881	0,675	0,100	0,860	20	0	0
20/11/2019	0,861	0,733	0,100	0,604	20	0	0
04/12/2019	0,900	0,683	0,100	0,868	10	0	0
05/12/2019	0,892	0,708	0,100	0,900	10	0	0
11/12/2019	0,839	0,758	0,107	0,700	20	0	0
25/12/2019	0,798	0,808	0,100	0,636	10	0	0
29/12/2019	0,828	0,817	0,100	0,380	10	0	0
30/12/2019	0,817	0,825	0,244	0,540	20	1	1

Lampiran 2. Hasil Pengujian Model Kedua

Tanggal	Tnavg	RHavg	RR	ss	ffavg	Expected	Got
02/01/2018	0,792	0,842	0,132	0,140	10	1	1
09/01/2018	0,781	0,867	0,100	0,460	0	0	0
11/01/2018	0,792	0,833	0,180	0,404	0	1	1
15/01/2018	0,812	0,800	0,100	0,260	10	0	0
19/01/2018	0,770	0,875	0,219	0,260	10	1	1
28/01/2018	0,842	0,750	0,100	0,500	40	0	0
01/02/2018	0,770	0,833	0,100	0,460	10	0	0
07/02/2018	0,795	0,825	0,127	0,300	10	1	0
10/02/2018	0,795	0,808	0,291	0,100	10	1	1
18/02/2018	0,831	0,800	0,220	0,340	10	1	1
19/02/2018	0,837	0,767	0,100	0,820	10	0	0
20/02/2018	0,814	0,792	0,100	0,660	10	0	0
22/02/2018	0,823	0,808	0,112	0,660	10	0	0
25/02/2018	0,776	0,842	0,182	0,476	0	1	1
06/03/2018	0,831	0,783	0,113	0,380	10	0	0
10/03/2018	0,828	0,783	0,100	0,780	10	0	0
17/03/2018	0,814	0,808	0,100	0,540	10	0	0
18/03/2018	0,792	0,825	0,104	0,500	0	0	0
21/03/2018	0,826	0,758	0,100	0,820	20	0	0
27/03/2018	0,798	0,825	0,100	0,380	10	0	0
14/04/2018	0,856	0,783	0,100	0,780	10	0	0
24/04/2018	0,864	0,742	0,100	0,620	10	0	0
29/04/2018	0,814	0,725	0,100	0,900	10	0	0
03/05/2018	0,790	0,725	0,100	0,900	20	0	0
23/05/2018	0,837	0,792	0,122	0,580	0	1	0
06/06/2018	0,828	0,800	0,100	0,780	0	0	0
07/06/2018	0,806	0,742	0,100	0,460	10	0	0
12/06/2018	0,809	0,767	0,100	0,660	10	0	0
20/06/2018	0,779	0,842	0,154	0,516	10	1	1
22/06/2018	0,779	0,833	0,142	0,140	0	1	1
25/06/2018	0,776	0,775	0,107	0,300	10	0	0
01/07/2018	0,795	0,700	0,100	0,740	0	0	0
07/07/2018	0,746	0,767	0,100	0,780	10	0	0
13/07/2018	0,754	0,767	0,100	0,740	20	0	0
16/07/2018	0,751	0,742	0,100	0,724	10	0	0
22/07/2018	0,820	0,750	0,100	0,500	20	0	0
30/07/2018	0,792	0,742	0,100	0,740	10	0	0
31/07/2018	0,781	0,775	0,100	0,620	10	0	0

03/08/2018	0,723	0,742	0,100	0,100	10	0	0
04/08/2018	0,712	0,750	0,100	0,100	20	0	0
11/08/2018	0,765	0,783	0,100	0,820	20	0	0
25/08/2018	0,743	0,725	0,100	0,884	10	0	0
31/08/2018	0,784	0,758	0,100	0,300	0	0	0
01/09/2018	0,790	0,775	0,100	0,380	10	0	0
05/09/2018	0,773	0,767	0,100	0,460	20	0	0
07/09/2018	0,781	0,767	0,100	0,540	10	0	0
09/09/2018	0,801	0,733	0,100	0,700	10	0	0
10/09/2018	0,823	0,733	0,100	0,860	10	0	0
13/09/2018	0,751	0,742	0,100	0,868	10	0	0
19/09/2018	0,817	0,783	0,100	0,500	0	0	0
21/09/2018	0,837	0,675	0,100	0,420	0	0	0
24/09/2018	0,850	0,700	0,100	0,700	10	0	0
25/09/2018	0,859	0,708	0,100	0,820	10	0	0
26/09/2018	0,842	0,700	0,100	0,860	20	0	0
29/09/2018	0,801	0,725	0,100	0,860	10	0	0
30/09/2018	0,831	0,708	0,100	0,100	10	0	0
07/10/2018	0,839	0,717	0,100	0,580	20	0	0
21/10/2018	0,834	0,742	0,100	0,100	10	0	0
27/10/2018	0,837	0,733	0,100	0,676	10	0	0
29/10/2018	0,820	0,733	0,100	0,740	10	0	0
15/11/2018	0,859	0,758	0,103	0,660	10	0	0
16/11/2018	0,856	0,742	0,100	0,420	10	0	0
27/11/2018	0,814	0,808	0,522	0,300	0	1	1
29/11/2018	0,784	0,858	0,110	0,100	0	0	0
30/11/2018	0,803	0,833	0,226	0,100	10	1	1
13/12/2018	0,853	0,792	0,100	0,460	10	0	0
18/12/2018	0,817	0,783	0,100	0,660	20	0	0
21/12/2018	0,839	0,783	0,418	0,220	10	1	1
23/12/2018	0,809	0,817	0,122	0,180	20	1	0
27/12/2018	0,826	0,783	0,144	0,420	10	1	1
01/01/2019	0,831	0,817	0,123	0,780	10	1	0
02/01/2019	0,820	0,767	0,169	0,260	10	1	1
05/01/2019	0,842	0,783	0,194	0,620	10	1	1
18/01/2019	0,831	0,817	0,305	0,300	10	1	1
22/01/2019	0,792	0,833	0,563	0,100	10	1	1
25/01/2019	0,776	0,867	0,511	0,500	10	1	1
26/01/2019	0,792	0,850	0,340	0,180	10	1	1
28/01/2019	0,861	0,742	0,100	0,700	20	0	0
04/02/2019	0,798	0,842	0,109	0,540	10	0	0

09/02/2019	0,823	0,817	0,100	0,228	0	0	0
11/02/2019	0,856	0,767	0,103	0,540	10	0	0
18/02/2019	0,837	0,800	0,100	0,700	0	0	0
20/02/2019	0,795	0,817	0,152	0,356	0	1	1
24/02/2019	0,814	0,800	0,100	0,620	10	0	0
09/03/2019	0,781	0,783	0,107	0,164	10	0	0
14/03/2019	0,842	0,767	0,100	0,580	10	0	0
20/03/2019	0,814	0,833	0,555	0,340	10	1	1
26/03/2019	0,837	0,825	0,100	0,676	10	0	0
02/04/2019	0,803	0,825	0,100	0,820	10	0	0
03/04/2019	0,812	0,817	0,100	0,620	10	0	0
08/04/2019	0,820	0,833	0,100	0,660	0	0	0
16/04/2019	0,814	0,825	0,135	0,500	10	1	1
21/04/2019	0,850	0,758	0,100	0,420	10	0	0
22/04/2019	0,848	0,750	0,100	0,620	10	0	0
28/04/2019	0,831	0,833	0,100	0,740	20	0	0
29/04/2019	0,814	0,817	0,231	0,500	10	1	1
01/05/2019	0,834	0,800	0,100	0,620	10	0	0
03/05/2019	0,837	0,758	0,100	0,860	10	0	0
11/05/2019	0,809	0,750	0,100	0,780	20	0	0
15/05/2019	0,850	0,750	0,100	0,660	10	0	0
20/05/2019	0,831	0,750	0,100	0,860	20	0	0
27/05/2019	0,831	0,758	0,100	0,500	10	0	0
29/05/2019	0,812	0,783	0,100	0,580	20	0	0
03/06/2019	0,798	0,792	0,100	0,340	20	0	0
06/06/2019	0,828	0,750	0,100	0,564	10	0	0
08/06/2019	0,773	0,783	0,100	0,740	10	0	0
14/06/2019	0,776	0,817	0,109	0,260	20	0	0
16/06/2019	0,806	0,708	0,100	0,820	10	0	0
08/07/2019	0,754	0,742	0,100	0,700	10	0	0
12/07/2019	0,740	0,742	0,100	0,508	10	0	0
21/07/2019	0,773	0,767	0,100	0,420	20	0	0
22/07/2019	0,762	0,742	0,100	0,532	20	0	0
24/07/2019	0,765	0,767	0,100	0,740	20	0	0
27/07/2019	0,790	0,742	0,100	0,740	10	0	0
28/07/2019	0,726	0,783	0,100	0,740	20	0	0
30/07/2019	0,765	0,742	0,100	0,860	20	0	0
31/07/2019	0,729	0,792	0,100	0,836	20	0	0
02/08/2019	0,773	0,750	0,100	0,820	20	0	0
03/08/2019	0,743	0,750	0,100	0,860	20	0	0
04/08/2019	0,726	0,717	0,100	0,780	40	0	0

06/08/2019	0,726	0,700	0,100	0,820	20	0	0
14/08/2019	0,792	0,742	0,100	0,476	10	0	0
20/08/2019	0,770	0,725	0,100	0,892	20	0	0
31/08/2019	0,765	0,733	0,100	0,820	20	0	0
11/09/2019	0,776	0,717	0,100	0,820	20	0	0
16/09/2019	0,787	0,733	0,100	0,740	10	0	0
19/09/2019	0,781	0,717	0,100	0,820	20	0	0
24/09/2019	0,826	0,733	0,100	0,540	10	0	0
25/09/2019	0,837	0,692	0,100	0,788	20	0	0
29/09/2019	0,809	0,742	0,100	0,660	10	0	0
10/10/2019	0,850	0,700	0,100	0,620	10	0	0
11/10/2019	0,870	0,633	0,100	0,780	20	0	0
18/10/2019	0,826	0,700	0,100	0,740	20	0	0
25/10/2019	0,853	0,700	0,100	0,860	10	0	0
26/10/2019	0,864	0,708	0,100	0,740	20	0	0
01/11/2019	0,861	0,717	0,100	0,780	20	0	0
05/11/2019	0,867	0,658	0,100	0,460	10	0	0
06/11/2019	0,823	0,742	0,100	0,780	10	0	0
11/11/2019	0,881	0,675	0,100	0,860	20	0	0
20/11/2019	0,861	0,733	0,100	0,604	20	0	0
04/12/2019	0,900	0,683	0,100	0,868	10	0	0
05/12/2019	0,892	0,708	0,100	0,900	10	0	0
11/12/2019	0,839	0,758	0,107	0,700	20	0	0
25/12/2019	0,798	0,808	0,100	0,636	10	0	0
29/12/2019	0,828	0,817	0,100	0,380	10	0	0
30/12/2019	0,817	0,825	0,244	0,540	20	1	1

Lampiran 3. Hasil Pengujian Model Ketiga

Tanggal	Tnavg	RHavg	RR	ss	ffavg	Expected	Got
02/01/2018	0,792	0,842	0,132	0,140	10	1	1
09/01/2018	0,781	0,867	0,100	0,460	0	0	0
11/01/2018	0,792	0,833	0,180	0,404	0	1	1
15/01/2018	0,812	0,800	0,100	0,260	10	0	0
19/01/2018	0,770	0,875	0,219	0,260	10	1	1
28/01/2018	0,842	0,750	0,100	0,500	40	0	0
01/02/2018	0,770	0,833	0,100	0,460	10	0	0
07/02/2018	0,795	0,825	0,127	0,300	10	1	1
10/02/2018	0,795	0,808	0,291	0,100	10	1	1
18/02/2018	0,831	0,800	0,220	0,340	10	1	1
19/02/2018	0,837	0,767	0,100	0,820	10	0	0
20/02/2018	0,814	0,792	0,100	0,660	10	0	0
22/02/2018	0,823	0,808	0,112	0,660	10	0	0
25/02/2018	0,776	0,842	0,182	0,476	0	1	1
06/03/2018	0,831	0,783	0,113	0,380	10	0	0
10/03/2018	0,828	0,783	0,100	0,780	10	0	0
17/03/2018	0,814	0,808	0,100	0,540	10	0	0
18/03/2018	0,792	0,825	0,104	0,500	0	0	0
21/03/2018	0,826	0,758	0,100	0,820	20	0	0
27/03/2018	0,798	0,825	0,100	0,380	10	0	0
14/04/2018	0,856	0,783	0,100	0,780	10	0	0
24/04/2018	0,864	0,742	0,100	0,620	10	0	0
29/04/2018	0,814	0,725	0,100	0,900	10	0	0
03/05/2018	0,790	0,725	0,100	0,900	20	0	0
23/05/2018	0,837	0,792	0,122	0,580	0	1	1
06/06/2018	0,828	0,800	0,100	0,780	0	0	0
07/06/2018	0,806	0,742	0,100	0,460	10	0	0
12/06/2018	0,809	0,767	0,100	0,660	10	0	0
20/06/2018	0,779	0,842	0,154	0,516	10	1	1
22/06/2018	0,779	0,833	0,142	0,140	0	1	1
25/06/2018	0,776	0,775	0,107	0,300	10	0	0
01/07/2018	0,795	0,700	0,100	0,740	0	0	0
07/07/2018	0,746	0,767	0,100	0,780	10	0	0
13/07/2018	0,754	0,767	0,100	0,740	20	0	0
16/07/2018	0,751	0,742	0,100	0,724	10	0	0
22/07/2018	0,820	0,750	0,100	0,500	20	0	0
30/07/2018	0,792	0,742	0,100	0,740	10	0	0
31/07/2018	0,781	0,775	0,100	0,620	10	0	0

03/08/2018	0,723	0,742	0,100	0,100	10	0	0
04/08/2018	0,712	0,750	0,100	0,100	20	0	0
11/08/2018	0,765	0,783	0,100	0,820	20	0	0
25/08/2018	0,743	0,725	0,100	0,884	10	0	0
31/08/2018	0,784	0,758	0,100	0,300	0	0	0
01/09/2018	0,790	0,775	0,100	0,380	10	0	0
05/09/2018	0,773	0,767	0,100	0,460	20	0	0
07/09/2018	0,781	0,767	0,100	0,540	10	0	0
09/09/2018	0,801	0,733	0,100	0,700	10	0	0
10/09/2018	0,823	0,733	0,100	0,860	10	0	0
13/09/2018	0,751	0,742	0,100	0,868	10	0	0
19/09/2018	0,817	0,783	0,100	0,500	0	0	0
21/09/2018	0,837	0,675	0,100	0,420	0	0	0
24/09/2018	0,850	0,700	0,100	0,700	10	0	0
25/09/2018	0,859	0,708	0,100	0,820	10	0	0
26/09/2018	0,842	0,700	0,100	0,860	20	0	0
29/09/2018	0,801	0,725	0,100	0,860	10	0	0
30/09/2018	0,831	0,708	0,100	0,100	10	0	0
07/10/2018	0,839	0,717	0,100	0,580	20	0	0
21/10/2018	0,834	0,742	0,100	0,100	10	0	0
27/10/2018	0,837	0,733	0,100	0,676	10	0	0
29/10/2018	0,820	0,733	0,100	0,740	10	0	0
15/11/2018	0,859	0,758	0,103	0,660	10	0	0
16/11/2018	0,856	0,742	0,100	0,420	10	0	0
27/11/2018	0,814	0,808	0,522	0,300	0	1	1
29/11/2018	0,784	0,858	0,110	0,100	0	0	0
30/11/2018	0,803	0,833	0,226	0,100	10	1	1
13/12/2018	0,853	0,792	0,100	0,460	10	0	0
18/12/2018	0,817	0,783	0,100	0,660	20	0	0
21/12/2018	0,839	0,783	0,418	0,220	10	1	1
23/12/2018	0,809	0,817	0,122	0,180	20	1	0
27/12/2018	0,826	0,783	0,144	0,420	10	1	1
01/01/2019	0,831	0,817	0,123	0,780	10	1	0
02/01/2019	0,820	0,767	0,169	0,260	10	1	1
05/01/2019	0,842	0,783	0,194	0,620	10	1	1
18/01/2019	0,831	0,817	0,305	0,300	10	1	1
22/01/2019	0,792	0,833	0,563	0,100	10	1	1
25/01/2019	0,776	0,867	0,511	0,500	10	1	1
26/01/2019	0,792	0,850	0,340	0,180	10	1	1
28/01/2019	0,861	0,742	0,100	0,700	20	0	0
04/02/2019	0,798	0,842	0,109	0,540	10	0	0

09/02/2019	0,823	0,817	0,100	0,228	0	0	0
11/02/2019	0,856	0,767	0,103	0,540	10	0	0
18/02/2019	0,837	0,800	0,100	0,700	0	0	0
20/02/2019	0,795	0,817	0,152	0,356	0	1	1
24/02/2019	0,814	0,800	0,100	0,620	10	0	0
09/03/2019	0,781	0,783	0,107	0,164	10	0	0
14/03/2019	0,842	0,767	0,100	0,580	10	0	0
20/03/2019	0,814	0,833	0,555	0,340	10	1	1
26/03/2019	0,837	0,825	0,100	0,676	10	0	0
02/04/2019	0,803	0,825	0,100	0,820	10	0	0
03/04/2019	0,812	0,817	0,100	0,620	10	0	0
08/04/2019	0,820	0,833	0,100	0,660	0	0	0
16/04/2019	0,814	0,825	0,135	0,500	10	1	1
21/04/2019	0,850	0,758	0,100	0,420	10	0	0
22/04/2019	0,848	0,750	0,100	0,620	10	0	0
28/04/2019	0,831	0,833	0,100	0,740	20	0	0
29/04/2019	0,814	0,817	0,231	0,500	10	1	1
01/05/2019	0,834	0,800	0,100	0,620	10	0	0
03/05/2019	0,837	0,758	0,100	0,860	10	0	0
11/05/2019	0,809	0,750	0,100	0,780	20	0	0
15/05/2019	0,850	0,750	0,100	0,660	10	0	0
20/05/2019	0,831	0,750	0,100	0,860	20	0	0
27/05/2019	0,831	0,758	0,100	0,500	10	0	0
29/05/2019	0,812	0,783	0,100	0,580	20	0	0
03/06/2019	0,798	0,792	0,100	0,340	20	0	0
06/06/2019	0,828	0,750	0,100	0,564	10	0	0
08/06/2019	0,773	0,783	0,100	0,740	10	0	0
14/06/2019	0,776	0,817	0,109	0,260	20	0	0
16/06/2019	0,806	0,708	0,100	0,820	10	0	0
08/07/2019	0,754	0,742	0,100	0,700	10	0	0
12/07/2019	0,740	0,742	0,100	0,508	10	0	0
21/07/2019	0,773	0,767	0,100	0,420	20	0	0
22/07/2019	0,762	0,742	0,100	0,532	20	0	0
24/07/2019	0,765	0,767	0,100	0,740	20	0	0
27/07/2019	0,790	0,742	0,100	0,740	10	0	0
28/07/2019	0,726	0,783	0,100	0,740	20	0	0
30/07/2019	0,765	0,742	0,100	0,860	20	0	0
31/07/2019	0,729	0,792	0,100	0,836	20	0	0
02/08/2019	0,773	0,750	0,100	0,820	20	0	0
03/08/2019	0,743	0,750	0,100	0,860	20	0	0
04/08/2019	0,726	0,717	0,100	0,780	40	0	0

06/08/2019	0,726	0,700	0,100	0,820	20	0	0
14/08/2019	0,792	0,742	0,100	0,476	10	0	0
20/08/2019	0,770	0,725	0,100	0,892	20	0	0
31/08/2019	0,765	0,733	0,100	0,820	20	0	0
11/09/2019	0,776	0,717	0,100	0,820	20	0	0
16/09/2019	0,787	0,733	0,100	0,740	10	0	0
19/09/2019	0,781	0,717	0,100	0,820	20	0	0
24/09/2019	0,826	0,733	0,100	0,540	10	0	0
25/09/2019	0,837	0,692	0,100	0,788	20	0	0
29/09/2019	0,809	0,742	0,100	0,660	10	0	0
10/10/2019	0,850	0,700	0,100	0,620	10	0	0
11/10/2019	0,870	0,633	0,100	0,780	20	0	0
18/10/2019	0,826	0,700	0,100	0,740	20	0	0
25/10/2019	0,853	0,700	0,100	0,860	10	0	0
26/10/2019	0,864	0,708	0,100	0,740	20	0	0
01/11/2019	0,861	0,717	0,100	0,780	20	0	0
05/11/2019	0,867	0,658	0,100	0,460	10	0	0
06/11/2019	0,823	0,742	0,100	0,780	10	0	0
11/11/2019	0,881	0,675	0,100	0,860	20	0	0
20/11/2019	0,861	0,733	0,100	0,604	20	0	0
04/12/2019	0,900	0,683	0,100	0,868	10	0	0
05/12/2019	0,892	0,708	0,100	0,900	10	0	0
11/12/2019	0,839	0,758	0,107	0,700	20	0	0
25/12/2019	0,798	0,808	0,100	0,636	10	0	0
29/12/2019	0,828	0,817	0,100	0,380	10	0	0
30/12/2019	0,817	0,825	0,244	0,540	20	1	1

Lampiran 4. Hasil Pengujian Model Keempat

Tanggal	Tnavg	RHavg	RR	ss	ffavg	Expected	Got
02/01/2018	0,792	0,842	0,132	0,140	10	1	1
09/01/2018	0,781	0,867	0,100	0,460	0	0	0
11/01/2018	0,792	0,833	0,180	0,404	0	1	1
15/01/2018	0,812	0,800	0,100	0,260	10	0	0
19/01/2018	0,770	0,875	0,219	0,260	10	1	1
28/01/2018	0,842	0,750	0,100	0,500	40	0	0
01/02/2018	0,770	0,833	0,100	0,460	10	0	0
07/02/2018	0,795	0,825	0,127	0,300	10	1	0
10/02/2018	0,795	0,808	0,291	0,100	10	1	1
18/02/2018	0,831	0,800	0,220	0,340	10	1	1
19/02/2018	0,837	0,767	0,100	0,820	10	0	0
20/02/2018	0,814	0,792	0,100	0,660	10	0	0
22/02/2018	0,823	0,808	0,112	0,660	10	0	0
25/02/2018	0,776	0,842	0,182	0,476	0	1	1
06/03/2018	0,831	0,783	0,113	0,380	10	0	0
10/03/2018	0,828	0,783	0,100	0,780	10	0	0
17/03/2018	0,814	0,808	0,100	0,540	10	0	0
18/03/2018	0,792	0,825	0,104	0,500	0	0	0
21/03/2018	0,826	0,758	0,100	0,820	20	0	0
27/03/2018	0,798	0,825	0,100	0,380	10	0	0
14/04/2018	0,856	0,783	0,100	0,780	10	0	0
24/04/2018	0,864	0,742	0,100	0,620	10	0	0
29/04/2018	0,814	0,725	0,100	0,900	10	0	0
03/05/2018	0,790	0,725	0,100	0,900	20	0	0
23/05/2018	0,837	0,792	0,122	0,580	0	1	1
06/06/2018	0,828	0,800	0,100	0,780	0	0	0
07/06/2018	0,806	0,742	0,100	0,460	10	0	0
12/06/2018	0,809	0,767	0,100	0,660	10	0	0
20/06/2018	0,779	0,842	0,154	0,516	10	1	1
22/06/2018	0,779	0,833	0,142	0,140	0	1	1
25/06/2018	0,776	0,775	0,107	0,300	10	0	0
01/07/2018	0,795	0,700	0,100	0,740	0	0	0
07/07/2018	0,746	0,767	0,100	0,780	10	0	0
13/07/2018	0,754	0,767	0,100	0,740	20	0	0
16/07/2018	0,751	0,742	0,100	0,724	10	0	0
22/07/2018	0,820	0,750	0,100	0,500	20	0	0
30/07/2018	0,792	0,742	0,100	0,740	10	0	0
31/07/2018	0,781	0,775	0,100	0,620	10	0	0

03/08/2018	0,723	0,742	0,100	0,100	10	0	0
04/08/2018	0,712	0,750	0,100	0,100	20	0	0
11/08/2018	0,765	0,783	0,100	0,820	20	0	0
25/08/2018	0,743	0,725	0,100	0,884	10	0	0
31/08/2018	0,784	0,758	0,100	0,300	0	0	0
01/09/2018	0,790	0,775	0,100	0,380	10	0	0
05/09/2018	0,773	0,767	0,100	0,460	20	0	0
07/09/2018	0,781	0,767	0,100	0,540	10	0	0
09/09/2018	0,801	0,733	0,100	0,700	10	0	0
10/09/2018	0,823	0,733	0,100	0,860	10	0	0
13/09/2018	0,751	0,742	0,100	0,868	10	0	0
19/09/2018	0,817	0,783	0,100	0,500	0	0	0
21/09/2018	0,837	0,675	0,100	0,420	0	0	0
24/09/2018	0,850	0,700	0,100	0,700	10	0	0
25/09/2018	0,859	0,708	0,100	0,820	10	0	0
26/09/2018	0,842	0,700	0,100	0,860	20	0	0
29/09/2018	0,801	0,725	0,100	0,860	10	0	0
30/09/2018	0,831	0,708	0,100	0,100	10	0	0
07/10/2018	0,839	0,717	0,100	0,580	20	0	0
21/10/2018	0,834	0,742	0,100	0,100	10	0	0
27/10/2018	0,837	0,733	0,100	0,676	10	0	0
29/10/2018	0,820	0,733	0,100	0,740	10	0	0
15/11/2018	0,859	0,758	0,103	0,660	10	0	0
16/11/2018	0,856	0,742	0,100	0,420	10	0	0
27/11/2018	0,814	0,808	0,522	0,300	0	1	1
29/11/2018	0,784	0,858	0,110	0,100	0	0	0
30/11/2018	0,803	0,833	0,226	0,100	10	1	1
13/12/2018	0,853	0,792	0,100	0,460	10	0	0
18/12/2018	0,817	0,783	0,100	0,660	20	0	0
21/12/2018	0,839	0,783	0,418	0,220	10	1	1
23/12/2018	0,809	0,817	0,122	0,180	20	1	0
27/12/2018	0,826	0,783	0,144	0,420	10	1	1
01/01/2019	0,831	0,817	0,123	0,780	10	1	0
02/01/2019	0,820	0,767	0,169	0,260	10	1	1
05/01/2019	0,842	0,783	0,194	0,620	10	1	1
18/01/2019	0,831	0,817	0,305	0,300	10	1	1
22/01/2019	0,792	0,833	0,563	0,100	10	1	1
25/01/2019	0,776	0,867	0,511	0,500	10	1	1
26/01/2019	0,792	0,850	0,340	0,180	10	1	1
28/01/2019	0,861	0,742	0,100	0,700	20	0	0
04/02/2019	0,798	0,842	0,109	0,540	10	0	0

09/02/2019	0,823	0,817	0,100	0,228	0	0	0
11/02/2019	0,856	0,767	0,103	0,540	10	0	0
18/02/2019	0,837	0,800	0,100	0,700	0	0	0
20/02/2019	0,795	0,817	0,152	0,356	0	1	1
24/02/2019	0,814	0,800	0,100	0,620	10	0	0
09/03/2019	0,781	0,783	0,107	0,164	10	0	0
14/03/2019	0,842	0,767	0,100	0,580	10	0	0
20/03/2019	0,814	0,833	0,555	0,340	10	1	1
26/03/2019	0,837	0,825	0,100	0,676	10	0	0
02/04/2019	0,803	0,825	0,100	0,820	10	0	0
03/04/2019	0,812	0,817	0,100	0,620	10	0	0
08/04/2019	0,820	0,833	0,100	0,660	0	0	0
16/04/2019	0,814	0,825	0,135	0,500	10	1	1
21/04/2019	0,850	0,758	0,100	0,420	10	0	0
22/04/2019	0,848	0,750	0,100	0,620	10	0	0
28/04/2019	0,831	0,833	0,100	0,740	20	0	0
29/04/2019	0,814	0,817	0,231	0,500	10	1	1
01/05/2019	0,834	0,800	0,100	0,620	10	0	0
03/05/2019	0,837	0,758	0,100	0,860	10	0	0
11/05/2019	0,809	0,750	0,100	0,780	20	0	0
15/05/2019	0,850	0,750	0,100	0,660	10	0	0
20/05/2019	0,831	0,750	0,100	0,860	20	0	0
27/05/2019	0,831	0,758	0,100	0,500	10	0	0
29/05/2019	0,812	0,783	0,100	0,580	20	0	0
03/06/2019	0,798	0,792	0,100	0,340	20	0	0
06/06/2019	0,828	0,750	0,100	0,564	10	0	0
08/06/2019	0,773	0,783	0,100	0,740	10	0	0
14/06/2019	0,776	0,817	0,109	0,260	20	0	0
16/06/2019	0,806	0,708	0,100	0,820	10	0	0
08/07/2019	0,754	0,742	0,100	0,700	10	0	0
12/07/2019	0,740	0,742	0,100	0,508	10	0	0
21/07/2019	0,773	0,767	0,100	0,420	20	0	0
22/07/2019	0,762	0,742	0,100	0,532	20	0	0
24/07/2019	0,765	0,767	0,100	0,740	20	0	0
27/07/2019	0,790	0,742	0,100	0,740	10	0	0
28/07/2019	0,726	0,783	0,100	0,740	20	0	0
30/07/2019	0,765	0,742	0,100	0,860	20	0	0
31/07/2019	0,729	0,792	0,100	0,836	20	0	0
02/08/2019	0,773	0,750	0,100	0,820	20	0	0
03/08/2019	0,743	0,750	0,100	0,860	20	0	0
04/08/2019	0,726	0,717	0,100	0,780	40	0	0

06/08/2019	0,726	0,700	0,100	0,820	20	0	0
14/08/2019	0,792	0,742	0,100	0,476	10	0	0
20/08/2019	0,770	0,725	0,100	0,892	20	0	0
31/08/2019	0,765	0,733	0,100	0,820	20	0	0
11/09/2019	0,776	0,717	0,100	0,820	20	0	0
16/09/2019	0,787	0,733	0,100	0,740	10	0	0
19/09/2019	0,781	0,717	0,100	0,820	20	0	0
24/09/2019	0,826	0,733	0,100	0,540	10	0	0
25/09/2019	0,837	0,692	0,100	0,788	20	0	0
29/09/2019	0,809	0,742	0,100	0,660	10	0	0
10/10/2019	0,850	0,700	0,100	0,620	10	0	0
11/10/2019	0,870	0,633	0,100	0,780	20	0	0
18/10/2019	0,826	0,700	0,100	0,740	20	0	0
25/10/2019	0,853	0,700	0,100	0,860	10	0	0
26/10/2019	0,864	0,708	0,100	0,740	20	0	0
01/11/2019	0,861	0,717	0,100	0,780	20	0	0
05/11/2019	0,867	0,658	0,100	0,460	10	0	0
06/11/2019	0,823	0,742	0,100	0,780	10	0	0
11/11/2019	0,881	0,675	0,100	0,860	20	0	0
20/11/2019	0,861	0,733	0,100	0,604	20	0	0
04/12/2019	0,900	0,683	0,100	0,868	10	0	0
05/12/2019	0,892	0,708	0,100	0,900	10	0	0
11/12/2019	0,839	0,758	0,107	0,700	20	0	0
25/12/2019	0,798	0,808	0,100	0,636	10	0	0
29/12/2019	0,828	0,817	0,100	0,380	10	0	0
30/12/2019	0,817	0,825	0,244	0,540	20	1	1