

**DETEKSI INDIKASI PENYAKIT ASMA MENGGUNAKAN
MULTI LAYER PERCEPTRON (MLP) MENGGUNAKAN
DATA REKAM MEDIS**

SKRIPSI

Oleh:

M. ZULFIKAR ALBAIHAQI
NIM. 220605110148



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**DETEKSI INDIKASI PENYAKIT ASMA MENGGUNAKAN
MULTI LAYER PERCEPTRON (MLP) MENGGUNAKAN
DATA REKAM MEDIS**

SKRIPSI

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

Oleh:
M. ZULFIKAR ALBAIHAQI
NIM. 220605110148

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN


DETEKSI INDIKASI PENYAKIT ASMA MENGGUNAKAN MULTI LAYER PERCEPTRON (MLP) MENGGUNAKAN DATA REKAM MEDIS

SKRIPSI


Oleh:
M. ZULFIKAR ALBAIHAQI
NIM. 220605110148

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 25 Juni 2026

Pembimbing I,


Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004

Pembimbing II,


Fatchurrochman, M.Kom
NIP. 19700731 200501 1 002

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




Supriyono, M.Kom
NIP. 19811010 201903 1 012

HALAMAN PENGESAHAN

DETEKSI INDIKASI PENYAKIT ASMA MENGGUNAKAN MULTI LAYER PERCEPTRON (MLP) MENGGUNAKAN DATA REKAM MEDIS


SKRIPSI

M. ZULFIKAR ALBAIHAQI
NIM. 220605110148

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 25 Juni 2026

Susunan Dewan Penguji

Ketua Penguji	: <u>Dr. Cahyo Crysdian, M.Cs</u> NIP. 19740424 200901 1 008
Anggota Penguji I	: <u>Tri Mukti Lestari, M.Kom</u> NIP. 19911108 202012 2 005
Anggota Penguji II	: <u>Dr. Irwan Budi Santoso, M.Kom</u> NIP. 19770103 201101 1 004
Anggota Penguji III	: <u>Fatchurrochman, M.Kom</u> NIP. 19700731 200501 1 002

()
()
()
()

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



PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : M. ZULFIKAR ALBAIHAQI
NIM : 220605110148
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Deteksi Indikasi Penyakit Asma Menggunakan
Multi Layer Perceptron (MLP) Menggunakan Data
Rekam Medis

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 2026
Yang membuat pernyataan,



M. ZULFIKAR ALBAIHAQI
NIM.220605110148

MOTTO

“Maybe Not Today, Maybe Not Tomorrow and not the next month. But only one thing is true I Will be Champion one day”

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur, karya ini penulis persembahkan kepada:

Ayah, Ibu, kakak dan adik

atas doa, dukungan, dan kasih sayang tanpa henti yang selalu menjadi sumber
kekuatan dan motivasi.

Dosen pembimbing dan para pengajar

atas bimbingan, arahan, serta ilmu yang sangat berarti bagi penulis.

Teman-teman Infinity Teknik Informatika 2022

yang telah menjadi bagian dari perjalanan ini melalui kebersamaan dan semangat
yang tidak pernah padam.

Dan akhirnya, untuk diri sendiri

yang terus berusaha, melangkah, dan bertahan hingga mencapai titik ini.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillahirabbil'alamin, segala puji syukur penulis panjatkan ke hadirat Allah SWT. atas limpahan rahmat, nikmat, dan hidayah-Nya, sehingga penulis dapat menyelesaikan tugas skripsi yang berjudul “DETEKSI INDIKASI ASMA MENGGUNAKAN MULTI LAYER PERCEPTRON (MLP) MENGGUNAKAN DATA REKAM MEDIS” dengan baik dan lancar. Shalawat serta salam tak lupa penulis sampaikan kepada Nabi Muhammad Shallallahu 'Alaihi Wasallam, sosok teladan mulia yang telah menuntun kita dari zaman kegelapan menuju zaman kebenaran, Islam, dan ilmu pengetahuan yang kita rasakan manfaatnya hingga hari ini.

Tugas skripsi ini disusun dalam rangka memenuhi salah satu syarat kelulusan untuk memperoleh gelar Sarjana Komputer pada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, UIN Maulana Malik Ibrahim Malang. Dalam proses penyusunan tugas ini, penulis mendapatkan bantuan, dukungan, serta doa dari banyak pihak, baik secara langsung maupun tidak langsung. Untuk itu, penulis ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., selaku Rektor Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
2. Dr. H. Agus Mulyono, S.Pd., M.Kes, selaku Dekan Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang.

3. Supriyono, M.Kom., selaku Ketua Program Studi S1 Teknik Informatika UIN Maulana Malik Ibrahim Malang sekaligus Dosen Wali.
4. Dr. Irwan Budi Santoso, M.Kom., selaku Dosen Pembimbing I, yang dengan kesabaran dan dedikasinya membimbing penulis selama penyusunan skripsi.
5. Fatchurrochman, M.Kom., selaku Dosen Pembimbing II, yang senantiasa memberikan arahan dan masukan yang sangat berharga dalam pengerjaan skripsi ini.
6. Dr. Cahyo Crysdiyan, M.Cs., dan Tri Mukti Lestari, M.Kom., selaku Dosen Penguji yang telah memberikan kritik, saran, dan bimbingan untuk menyempurnakan skripsi ini.
7. Nia Faricha, S.Si., admin Program Studi Teknik Informatika, yang membantu dalam urusan administrasi dan selalu mengingatkan tentang kelengkapan berkas.
8. Bapak KHOIRUL MUSTOFA dan Ibu MUCHMILATUL KHUSNAH, orang tua tercinta, serta ACHMAD AL ARIFIL MUSTOFA, kakak saya, yang Dimana mereka semua senantiasa menjadi sumber kekuatan melalui doa, kasih sayang, dan dukungan tanpa henti.
9. Seluruh keluarga, teman, sahabat, dan kerabat penulis yang tidak dapat penulis sebutkan satu per satu, yang turut memberikan bantuan, semangat, dukungan, dan doa untuk penulis.
10. Teman bertumbuh “2RU” yang beranggotakan Maul, Sada, Izzan, Rezha. Yang membersamai baik ketika berada dikala senang maupun sedih.

11. Teman Perjuangan Yakni yudistira irfandalfiali dwiphayana yang senantiasa membantu dalam susah dan senang dalam perkuliahan dalam hidup saya

Dan terakhir tak lupa terimakasih kepada diri sendiri, yang dengan tekad kuat mampu melewati setiap tantangan, rintangan, dan kesulitan selama perjalanan ini, membuktikan bahwa kerja keras dan usaha tidak pernah sia-sia. Penulis menyadari bahwa penelitian dalam tugas skripsi ini masih jauh dari kata sempurna dan memiliki berbagai keterbatasan. Oleh karena itu, dengan penuh kerendahan hati, penulis membuka diri untuk menerima kritik dan saran yang membangun dari para pembaca guna menjadi bahan evaluasi dan pengembangan di masa mendatang. Penelitian ini juga memiliki potensi untuk dilanjutkan dan dikembangkan lebih jauh dalam penelitian berikutnya, sehingga dapat melengkapi kekurangan yang ada. Penulis berharap, karya ini tidak hanya memberikan manfaat bagi pembaca, tetapi juga dapat berkontribusi positif bagi masyarakat secara luas.

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Malang, 8 Mei 2026

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	iii
DAFTAR GAMBAR.....	v
DAFTAR TABEL	vi
ABSTRAK	vii
ABSTRACT	viii
مستخلص البحث.....	ix
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
BAB II STUDI PUSTAKA	6
2.1 Analisis Penyakit Asma	6
2.2 Asma	11
2.3 Multilayer Perceptron (MLP).....	14
BAB III DESAIN DAN IMPLEMENTASI	16
3.1 Desain Penelitian.....	16
3.2 Pengumpulan Data	17
3.2.1 Experimen Data	17
3.2.2 Augmentasi Data Menggunakan Smote	19
3.3 Desain Sistem.....	20
3.3.1 Pra-Pemrosesan Data	21
3.3.2 Arsitektur Multilayer Perceptron	23
3.4 Implementasi	34
BAB IV HASIL DAN PEMBAHASAN	40
4.1 Persiapan Data.....	40
4.2 Skenario Uji Coba	43
4.2.1 Hasil Uji Coba Skenario 1	47
4.2.2 Hasil Uji Coba Skenario 2	51
4.2.3 Hasil Uji Coba Skenario 3	54
4.2.4 Hasil Uji Coba Skenario 4	57
4.3 Hasil Uji Coba Data <i>Balanced</i>	60
4.3.1 Hasil Uji Coba Skenario 5	61
4.3.2 Hasil Uji Coba Skenario 6	64
4.3.3 Hasil Uji Coba Skenario 7	67
4.3.4 Hasil Uji Coba Skenario 8	70

4.4 Pembahasan.....	73
4.4.1 Pengaruh Arsitektur MLP (Hidden Layer dan Neuron)	76
4.4.2 Pengaruh Keseimbangan Data	78
4.5 Implementasi GUI.....	80
BAB V KESIMPULAN DAN SARAN	85
5.1 Kesimpulan	85
5.2 Saran	86
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 3.1 Desain Sistem.....	21
Gambar 3.2 Arsitektur Multilayer Perceptron(MLP)	25
<i>Gambar 4.1</i> Dataset Kelas Asma	41
Gambar 4.2 Jumlah Data Pada Proses SMOTETomek.....	43
Gambar 4.3 visualisasi Confusion Matrix Model 1	49
Gambar 4.4 Grafik Training Loss Model MLP Skenario 1	50
Gambar 4.5 Grafik Training Accuracy Model MLP Skenario 1	51
Gambar 4.6 Visualisasi Confusion Matrix Model 2	52
Gambar 4.7 Grafik Training Loss Model MLP Skenario 2	53
Gambar 4.8 Grafik Training Accuracy Model MLP Skenario 2	54
Gambar 4.9 Visualisasi Confusion Matrix Model 3	55
Gambar 4.10 Grafik Training Loss Model MLP Skenario 3	56
Gambar 4.11 Grafik Training Accuracy Model MLP Skenario 3	57
Gambar 4.12 Visualisasi Confusion Matrix Model 4	58
Gambar 4.13 Grafik Training Loss Model MLP Skenario 4	59
Gambar 4.14 Grafik Training Accuracy Model MLP Skenario 4	60
Gambar 4.15 Visualisasi Confusion Matrix Model 5	62
Gambar 4.16 Grafik Training Loss Model MLP Skenario 5	63
Gambar 4.17 Grafik Training Accuracy Model MLP Skenario 5	64
Gambar 4.18 Visualisasi Confusion Matrix Model 6	65
Gambar 4.19 Grafik Training Loss Model MLP Skenario 6	66
Gambar 4.20 Grafik Training Accuracy Model MLP Skenario 6	67
Gambar 4.21 Visualisasi Confusion Matrix Model 7	68
Gambar 4.22 Grafik Training Loss Model MLP Skenario 7	69
Gambar 4.23 Grafik Training Accuracy Model MLP Skenario 7	70
Gambar 4.24 Visualisasi Confusion Matrix Model 8	71
Gambar 4.25 Grafik Training Loss Model MLP Skenario 8	72
Gambar 4.26 Grafik Training Accuracy Model MLP Skenario 8	73
Gambar 4.27 Tampilan Gui Input Data.....	81
Gambar 4.28 Hasil Indikasi Asma	82

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu dengan Machine Learning	9
Tabel 4.1 Kombinasi Pengujian MLP	44
Tabel 4.2 Hasil Klasifikasi Berdasarkan Kelas Negatif dan Positif.....	47
Tabel 4.3 Hasil Uji Coba Skenario 1	48
Tabel 4.4 Hasil Uji Coba Skenario 2	51
Tabel 4.5 Hasil Uji Coba Skenario 3	54
Tabel 4.6 Hasil Uji Coba Skenario 4	57
Tabel 4.7 Hasil Uji Coba Skenario 5	62
Tabel 4.8 Hasil Uji Coba Skenario 6	65
Tabel 4.9 Hasil Uji Coba Skenario 7	68
Tabel 4.10 Hasil Uji Coba Skenario 8	71
Tabel 4.11 Hasil Evaluasi Menggunakan Tanpa SMOTE	74
Tabel 4.12 Hasil Evaluasi Menggunakan SMOTE	75
Tabel 4.13 Perbandingan Hidden Layer 2	76
Tabel 4.14 Perbandingan Hidden Layer 3.....	77
Tabel 4.15 Perbandingan Rata Rata Hasil Precision Recall F1 Score Pada Data. 78	

ABSTRAK

Albaihaqi, M. Zulfikar. 2026. **Deteksi Indikasi Penyakit Asma Menggunakan Metode Multi layer Perceptron (MLP) Menggunakan Data Rekam Medis**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Irwan Budi Santoso, M.Kom. (II) Fatchurrochman, M.Kom.

Kata kunci: Asma, Multilayer Perceptron (MLP), SMOTE, Deteksi Dini.

Penyakit asma merupakan salah satu penyakit pernapasan kronis yang dapat menurunkan kualitas hidup penderitanya sehingga diperlukan deteksi dini untuk membantu penanganan yang lebih cepat dan tepat. Penelitian ini bertujuan untuk menganalisis performa metode Multilayer Perceptron (MLP) dalam mendeteksi indikasi penyakit asma berdasarkan data rekam medis serta mengevaluasi pengaruh penyeimbangan data menggunakan Synthetic Minority Oversampling Technique (SMOTE) dan variasi arsitektur jaringan terhadap kinerja model. Penelitian dilakukan melalui tahapan pra-pemrosesan data, penyeimbangan kelas menggunakan SMOTE, perancangan beberapa arsitektur MLP, serta evaluasi menggunakan metode 5-Fold Cross Validation. Hasil pengujian pada kondisi data imbalanced menghasilkan rata-rata Accuracy sebesar 97,95%, Precision sebesar 85,64%, Recall sebesar 73,46%, dan F1-Score sebesar 78,65%. Sementara itu, pada kondisi data balanced menggunakan SMOTE diperoleh rata-rata Accuracy sebesar 97,94%, Precision sebesar 83,84%, Recall sebesar 74,95%, dan F1-Score sebesar 78,92%. Konfigurasi arsitektur terbaik diperoleh pada model 20-64-32-16-1 dengan data balanced yang menghasilkan Accuracy sebesar 98,12%, Precision sebesar 84,38%, Recall sebesar 78,74%, dan F1-Score sebesar 81,22%. Hasil penelitian menunjukkan bahwa penerapan SMOTE mampu meningkatkan kemampuan model dalam mengenali kelas minoritas, sedangkan peningkatan jumlah neuron memberikan pengaruh yang lebih konsisten terhadap performa model dibandingkan penambahan hidden layer. Secara keseluruhan, metode Multilayer Perceptron (MLP) dapat digunakan secara efektif untuk mendeteksi indikasi penyakit asma berdasarkan data rekam medis dengan performa klasifikasi yang baik.

ABSTRACT

Albaihaqi, M. Zulfikar. 2026. **Detection of Asthma Indicators Using the Multilayer Perceptron (MLP) Method Based on Medical Record Data.** Undergraduate Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, State Islamic University (UIN) Maulana Malik Ibrahim Malang. Supervisors: (I) Dr. Irwan Budi Santoso, M.Kom. (II) Fatchurrochman, M.Kom.

Keywords: Asthma, Multilayer Perceptron (MLP), SMOTE, Early Detection.

Asthma is a chronic respiratory disease that can reduce the quality of life of sufferers, necessitating early detection to facilitate faster and more appropriate management. This study aims to analyze the performance of the Multilayer Perceptron (MLP) method in detecting indications of asthma based on medical record data, as well as to evaluate the effect of data balancing using the Synthetic Minority Oversampling Technique (SMOTE) and variations in network architecture on model performance. The research was conducted through the stages of data preprocessing, class balancing using SMOTE, designing several MLP architectures, and evaluation using the 5-Fold Cross-Validation method. Testing on the imbalanced data condition yielded an average Accuracy of 97.95%, Precision of 85.64%, Recall of 73.46%, and an F1-Score of 78.65%. Meanwhile, under the balanced data condition using SMOTE, the average Accuracy was 97.94%, Precision was 83.84%, Recall was 74.95%, and the F1-Score was 78.92%. The best architectural configuration was achieved by the 20-64-32-16-1 model with balanced data, producing an Accuracy of 98.12%, Precision of 84.38%, Recall of 78.74%, and an F1-Score of 81.22%. The results demonstrate that the application of SMOTE enhances the model's ability to recognize the minority class, while increasing the number of neurons provides a more consistent impact on model performance compared to adding hidden layers. Overall, the Multilayer Perceptron (MLP) method can be effectively utilized to detect indications of asthma based on medical record data with strong classification performance.

مستخلص البحث

ألباهياقي، م. زلفكار. 2026. الكشف عن مؤشرات مرض الربو باستخدام طريقة الشبكة العصبية متعددة الطبقات (MLP) استناداً إلى بيانات السجلات الطبية. أطروحة تخرج. برنامج هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرفان: (I) د. إيروان بودي سانتوسو، ماجستير في علوم الحاسوب. (II) فاتشوروشمان، ماجستير في علوم الحاسوب.

الكلمات المفتاحية: الربو، الشبكة العصبية متعددة الطبقات (SMOTE)، MLP، الكشف المبكر.

يُعَد مرض الربو أحد أمراض الجهاز التنفسي المزمنة التي يمكن أن تقلل من جودة حياة المصابين به، لذا فإن الكشف المبكر ضروري للمساعدة في العلاج بشكل أسرع وأكثر دقة. تهدف هذه الدراسة إلى تحليل أداء طريقة الشبكة العصبية متعددة الطبقات (MLP) في الكشف عن مؤشرات مرض الربو استناداً إلى بيانات السجلات الطبية، وتقييم تأثير موازنة البيانات باستخدام تقنية أخذ العينات الزائدة للأقلية الاصطناعية (SMOTE) وتأثير تنوع بنية الشبكة على أداء النموذج. أُجريت الدراسة من خلال مراحل ما قبل معالجة البيانات، وموازنة الفئات باستخدام تقنية SMOTE، وتصميم عدة هياكل لشبكة MLP، والتقييم باستخدام طريقة التحقق المتقاطع الخماسي (Cross-Validation Fold 5). أسفرت نتائج الاختبار في حالة البيانات غير المتوازنة عن متوسط دقة (Accuracy) بلغ 97,95%، ودقة تحديد (Precision) بلغت 85,64%، ومعدل الاسترجاع (Recall) بلغ 73,46%، ومؤشر F1-Score بلغ 78,65%. في المقابل، في حالة البيانات المتوازنة باستخدام SMOTE، تم الحصول على دقة متوسطة بلغت 97,94%، ودقة تحديد بلغت 83,84%، ومعدل استرجاع بلغ 74,95%، ودرجة F1 بلغت 78,92%. تم الحصول على أفضل تكوين للهندسة المعمارية في النموذج 1-16-32-64-20 مع البيانات المتوازنة، مما أدى إلى دقة بنسبة 98,12%، ودقة تحديد بنسبة 84,38%، ومعدل استرجاع بنسبة 78,74%، ودرجة F1 بنسبة 81,22%. أظهرت نتائج البحث أن تطبيق SMOTE قادر على تحسين قدرة النموذج على التعرف على الفئات الأقلية، في حين أن زيادة عدد الخلايا العصبية تؤثر بشكل أكثر اتساقاً على أداء النموذج مقارنةً بإضافة طبقة خفية. وبشكل عام، يمكن استخدام طريقة MLP (Multilayer Perceptron) بفعالية للكشف عن مؤشرات مرض الربو استناداً إلى بيانات السجلات الطبية مع أداء تصنيف جيد.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit pada gangguan saluran pernapasan merupakan salah satu masalah kesehatan yang memiliki dampak signifikan terhadap kualitas hidup manusia. Gangguan tersebut dapat menyebabkan penurunan fungsi paru, keterbatasan aktivitas sehari-hari, sehingga peningkatan risiko komplikasi serius jika tidak ditangani secara tepat (Da Silva et al., 2023). Seiring dengan perkembangan teknologi dan meningkatnya ketersediaan data rekam medis, pendekatan berbasis komputasi mulai banyak dimanfaatkan untuk membantu proses deteksi dini dan pengambilan keputusan klinis. Asma merupakan penyakit peradangan kronis pada saluran napas yang ditandai oleh penyempitan jalan napas secara reversibel dan meningkatnya sensitivitas bronkus terhadap berbagai rangsangan eksternal. Kondisi ini muncul akibat interaksi kompleks antara faktor genetik dan lingkungan, termasuk paparan alergen, polusi udara, infeksi saluran pernapasan, serta gaya hidup modern yang memengaruhi sistem imun dan fungsi paru (Qaida & Long, 2025). Dampak klinis asma tidak hanya terbatas pada gangguan pernapasan, tetapi juga berimplikasi pada penurunan produktivitas, peningkatan beban ekonomi, serta penurunan kualitas hidup penderita (Rabe et al., 2023). Dengan prevalensi yang terus meningkat di berbagai negara, asma menjadi isu kesehatan masyarakat global yang menuntut perhatian serius dalam hal pencegahan, deteksi dini, dan manajemen jangka panjang (World Health Organization [WHO], 2022). Berdasarkan tingkat

keparahan dan frekuensi gejalanya, asma diklasifikasikan menjadi beberapa kategori seperti intermiten, persisten ringan, persisten sedang, dan persisten berat, yang menjadi dasar dalam menentukan strategi terapi yang tepat (Mortimer et al., 2022). . Penundaan diagnosis atau kegagalan dalam memantau kondisi asma secara efektif dapat memicu komplikasi serius yang berpotensi mengancam jiwa. Salah satu risiko utama adalah terjadinya eksaserbasi atau serangan asma berat, di mana penyempitan saluran napas menjadi sangat parah sehingga pertukaran oksigen terganggu (Ojanguren et al., 2025). Oleh karena itu, diagnosis dini dan manajemen yang tepat menjadi krusial untuk mengontrol gejala (García-Marcos et al., 2023).

Selain itu, dalam penelitian kesehatan dapat ditemukan panduan dan referensi yang berharga dalam hadis dan ayat-ayat Al-Quran yang menekankan pentingnya menjaga kesehatan dan mengutamakan tindakan pencegahan. Seperti yang terkandung dalam Al-Qur'an Surat An nahl Ayat 69:

يَا أَيُّهَا النَّاسُ قَدْ جَاءَكُمْ مَوْعِظَةٌ مِنْ رَبِّكُمْ وَشِفَاءٌ لِمَا فِي الصُّدُورِ وَهُدًى وَرَحْمَةٌ لِّلْمُؤْمِنِينَ ثُمَّ كُلُوا مِن كُلِّ الثَّمَرَاتِ فَاسْلُكُوا سُبُلَ رَبِّكُمْ ذَٰلِكُمْ يَخْرُجُ مِنْ بُطُونِهَا شَرَابٌ مُّخْتَلِفٌ أَلْوَنُهُ فِيهِ شِفَاءٌ لِّلنَّاسِ ۚ إِنَّ فِي ذَٰلِكَ لَآيَةً لِّقَوْمٍ يَتَفَكَّرُونَ

“Kemudian makanlah dari tiap-tiap (macam) buah-buahan dan tempuhlah jalan Tuhanmu yang telah dimudahkan (bagimu). Dari perut lebah itu ke luar minuman (madu) yang bermacam-macam warnanya, di dalamnya terdapat obat yang menyembuhkan bagi manusia. Sesungguhnya pada yang demikian itu benar-benar terdapat tanda (kebesaran Tuhan) bagi orang-orang yang memikirkan.” (Q.S An-Nahl: 69).

Berdasarkan Tafsir Ringkas Kementerian Agama Republik Indonesia, Q.S. An-Nahl 69 dari perut lebah itu keluar sejenis minuman yang amat lezat berupa madu yang bermacam-macam warna dan rasa-Nya. Di dalamnya terdapat

kandungan yang bermanfaat bagi daya tahan tubuh dan obat yang dapat menyembuhkan bagi beberapa penyakit manusia. (*Qur'an Kemenag*, n.d.).

Dari ayat Al-Quran di atas, kita dapat mengambil pelajaran bahwa dalam Islam menjaga kesehatan dan mencegah penyakit diutamakan. Kesehatan dianggap sebagai anugerah dan Allah telah memberikan obat atau solusi untuk setiap penyakit. Dengan merujuk pada petunjuk dalam Al-Quran dan hadis, umat Islam diajak untuk menghargai nikmat kesehatan yang diberikan oleh Allah dan berusaha menjaga kesehatan tubuh sebagai bentuk syukur. Kesadaran untuk mencegah penyakit juga diterapkan sebagai bentuk ikhtiar dan tindakan preventif dalam menjaga amanah kesehatan yang diberikan oleh-Nya.

Penelitian sebelumnya mengenai prediksi risiko asma banyak menggunakan pendekatan *machine learning* dengan algoritma klasik seperti *Support Vector Machine* (SVM), *Random Forest* (RF), dan *Naïve Bayes* yang terbukti memiliki akurasi yang memadai (Budiarto et al., 2023). Namun, model-model tersebut memiliki keterbatasan dalam menangkap hubungan non-linear yang kompleks pada data klinis. Selain itu, sebagian besar penelitian masih menerapkan klasifikasi biner (asma vs non-asma) atau terbatas pada analisis statistik tanpa mendalami arsitektur *deep learning* yang lebih dalam (Kothalawala et al., 2020). Oleh karena itu, pengembangan model *deep learning* yang sederhana namun powerful untuk klasifikasi asma menjadi solusi yang dibutuhkan untuk mengatasi permasalahan tersebut. Dalam penelitian ini akan menggunakan pendekatan klasifikasi untuk membedakan antara subjek sehat dan subjek dengan asma. Penelitian ini akan mengusulkan model *deep learning* yang efisien secara komputasi dan cocok untuk

dataset yang tidak terlalu besar, yaitu *Multilayer Perceptron* (MLP). MLP dipilih karena memiliki kemampuan untuk mempelajari representasi non-linear dari data, sehingga cocok digunakan untuk menangkap pola kompleks dari fitur-fitur klinis seperti faktor gaya hidup, faktor lingkungan dan alergi, riwayat medis, pengukuran klinis, dan gejala. Oleh karena itu *Multilayer Perceptron* (MLP) digunakan menginvestigasi kemampuan model MLP dalam menangkap pola non-linier yang kompleks dari berbagai fitur klinis. Kombinasi ini diharapkan dapat menghasilkan model yang tidak hanya akurat tetapi juga robust dan tidak bias.

penggunaan metode *Multilayer Perceptron* (MLP) dalam penelitian ini diharapkan dapat menjadi pendekatan yang efektif dalam mendeteksi risiko asma secara lebih akurat. Dengan kemampuannya dalam mempelajari hubungan non-linear dan kompleks antar variabel klinis, MLP berpotensi mengatasi keterbatasan yang terdapat pada algoritma machine learning sebelumnya. Penerapan model ini diharapkan mampu memberikan kontribusi nyata dalam pengembangan sistem pendukung keputusan medis berbasis kecerdasan buatan yang dapat membantu tenaga kesehatan dalam melakukan diagnosis dini dan pemantauan kondisi pasien asma. Selain itu, hasil penelitian ini diharapkan dapat menjadi dasar bagi pengembangan model-model deep learning lainnya dalam bidang kesehatan, khususnya untuk mendeteksi penyakit dengan karakteristik multifaktorial seperti asma.

1.2 Pernyataan Masalah

Bagaimana performa model Multilayer Perceptron (MLP) untuk deteksi indikasi asma menggunakan data rekam medis.

1.3 Batasan Masalah

Penelitian ini dibatasi pada penggunaan dataset kumpulan data penyakit asma yang diperoleh dari Kaggle (Rabie El Kharoua 2024). Data ini mencakup detail demografi, faktor gaya hidup, faktor lingkungan dan alergi, riwayat medis, pengukuran klinis, gejala, dan indikator diagnosis.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah merancang dan mengevaluasi model Multilayer Perceptron (MLP) untuk memprediksi risiko asma pada pasien berdasarkan data yang tersedia, serta menganalisis kemampuan model dalam mempelajari pola hubungan antar variabel guna menghasilkan sistem prediksi yang akurat dan dapat mendukung proses deteksi dini penyakit asma.

1.5 Manfaat Penelitian

Penelitian ini bermanfaat untuk mengembangkan penerapan kecerdasan buatan, khususnya model Multilayer Perceptron (MLP), dalam memprediksi risiko asma secara akurat dan efisien. Hasil penelitian ini dapat membantu tenaga medis dan pasien dalam melakukan deteksi dini risiko asma, sehingga dapat mendukung pengambilan keputusan serta meningkatkan kualitas layanan kesehatan.

BAB II

STUDI PUSTAKA

2.1 Analisis Penyakit Asma

Berbagai penelitian telah dilakukan untuk meningkatkan akurasi diagnosis dan prediksi asma menggunakan pendekatan *Machine Learning* (ML) maupun *Deep Learning* (DL). Studi oleh Kohandel Gargari et al. (2025) yang dipublikasikan di *Scientific Reports* membandingkan tujuh algoritma ML menggunakan data NHANES 2017–2018 dari 8.888 partisipan. Hasilnya menunjukkan bahwa *Support Vector Machine* (SVM) dan AdaBoost (ADA) mencapai performa terbaik dengan AUC masing-masing 0,72 dan 0,71. Analisis SHAP mengungkap tiga prediktor paling signifikan: riwayat asma keluarga, asupan lemak, dan riwayat bronkitis kronis. Meski menjanjikan, studi ini memiliki keterbatasan berupa diagnosis berbasis *self-report* dan tidak adanya validasi eksternal.

Tomita et al. (2023) dalam jurnal *Diagnostics* mengembangkan algoritma diagnostik asma menggunakan *Random Forest* (RF) dan XGBoost, dengan model XGBoost mencapai akurasi 81% dan AUC 85% dari 566 pasien. Temuan penting studi ini adalah ketika data fungsi paru tersedia, pengukuran %V50 menjadi prediktor terpenting; sedangkan tanpa data tersebut, gejala berulang dan kadar FeNO menjadi fitur kunci. Studi sebelumnya oleh Tomita et al. (2019) juga membandingkan *Deep Neural Network* (DNN) dengan SVM dan regresi logistik, di mana DNN unggul signifikan dengan akurasi 98% menggunakan 22 fitur klinis, melampaui SVM (82%) dan regresi logistik (94%).

Haque et al. (2021) dalam *F1000Research* mengembangkan model *Deep Neural Network Regression* (DNNR) untuk memprediksi skor *Asthma Control Test* (ACT) berdasarkan faktor cuaca dan demografi dari 10 pengguna aplikasi seluler. Setelah optimisasi melalui standardisasi data dan *fragmented-grid-search*, model mencapai akurasi 94% dengan MAE=0,20, meski keterbatasan ukuran sampel yang kecil membatasi generalisasinya.

Pada konteks prediksi kunjungan gawat darurat anak penderita asma, AlSaad et al. (2022) dalam *Healthcare Analytics* memanfaatkan data *Electronic Health Record* (HER) dari 87.413 pasien anak untuk membandingkan berbagai arsitektur RNN. Model BiLSTM, BiGRU, dan RETAIN secara konsisten mengungguli regresi logistik multinomial, dengan AUC-ROC 0,85 dan F1-score 0,61 dibanding 0,81 dan 0,56 pada model dasar. Studi ini menegaskan efektivitas pemodelan temporal berbasis RNN untuk identifikasi pasien berisiko tinggi.

Pooja M. R et al. (2024) dalam *The Open Bioinformatics Journal* mengatasi tantangan ketidakseimbangan kelas parah (187 asma vs. 1.362 non-asma) menggunakan *One-Class Support Vector Machines* (OCSVM) untuk menyeimbangkan dataset dari 1.549 anak di Austria. Dengan rekayasa fitur ekstensif yang menghasilkan indeks klinis baru seperti Tiffeneau-Pinelli index, model *Naïve Bayes* mencapai presisi 86,1%, recall 84,7%, dan AUC 92,2%, membuktikan pentingnya kombinasi rekayasa fitur dan data riwayat medis.

Lopez et al. (2023) dalam *Respiratory Research* menggunakan data *Electronic Health Record* (EHR) retrospektif dari 5.794 pasien di Yale-New Haven Hospital untuk membandingkan empat model ML konvensional dan satu model DL

berupa *Multilayer Perceptron* (MLP). Model MLP menunjukkan performa paling unggul bukan karena AUC tertinggi, melainkan karena mencapai keseimbangan terbaik antara sensitivitas (79%) dan spesifisitas (79%), yang konsisten pada subkelompok asma maupun PPOK.

Xiang et al. (2020) dalam *Journal of Medical Internet Research* mengusulkan model *Time-Sensitive, Attentive Neural Network* (TSANN) berbasis LSTM dengan mekanisme atensi hirarkis yang memodelkan jeda waktu antar kunjungan klinis secara inovatif. Diuji pada 31.433 pasien asma dari database Cerner Health Facts, TSANN mencapai AUC 0,7003 melalui validasi silang lima kali lipat, mengungguli regresi logistik dan model RETAIN, sekaligus mampu mengidentifikasi faktor risiko seperti penyakit pernapasan lain dan refluks esofagus.

Kothalawala et al. (2021) dalam *Clinical and Translational Allergy* mengembangkan dua model prediksi asma masa kanak-kanak berbasis ML menggunakan data *Isle of Wight Birth Cohort* (N=1.368). Model CAPE (data ≤ 2 tahun) dan CAPP (data ≤ 4 tahun) dengan algoritma SVM terbaik mencapai AUC 0,71 dan 0,82 secara berturut-turut, dengan validasi eksternal pada kohort MAAS yang menunjukkan generalisasi baik.

Chen et al. (2025) dalam jurnal *Healthcare* memperkenalkan sistem prediksi asma non-invasif berbasis analisis akustik suara. Menggunakan 1.500 sampel dari *Saarbruecken Voice Database* dan fitur akustik LTAS serta SFCC, model *Gradient Boosting Decision Trees* (GBDT) pada fonem bernada tinggi mencapai akurasi tertinggi 88,6%. Temuan ini menunjukkan bahwa rentang frekuensi 450–500 Hz

dapat menjadi penanda akustik signifikan yang membedakan penderita asma dari individu sehat.

Tabel 2.1 menjelaskan beberapa penelitian terdahulu yang menerapkan beberapa metode untuk melakukan klasifikasi terhadap asma yang telah banyak dilakukan sebelumnya.

Tabel 2.1 Penelitian Terdahulu dengan Machine Learning

No.	Penulis	Metode	Hasil	Perbedaan Penelitian
1.	Assessing the diagnostic accuracy of machine learning algorithms for identification of asthma in United States adults based on NHANES dataset Oleh Kohandel Gargari dkk., (2025)	SVM, Random Forest, AdaBoost, XGBoost, KNN, Naive Bayes, MLP	SVM dan ADA tertinggi AUC 0.72 dan 0.71; RF akurasi tinggi, presisi rendah; SHAP values identifikasi fitur signifikan	Dataset dan konfigurasi MLP
2.	Construction of a Diagnostic Algorithm for Diagnosis of Adult Asthma Using Machine Learning with Random Forest and XGBoost Oleh Tomita dkk., (2023)	Random Forest, XGBoost	Model XGBoost menghasilkan akurasi 85%	Metode Algoritma MLP dan SMOTE
3.	Establishment of a predictive model on asthma diagnosis using environmental and allergy factors Oleh Xinqi Huang (2025)	Logistic Regression, Random Forest, SMOTETomek, Pearson correlation, confusion matrix	Random Forest lebih unggul; pollen exposure prediktif; dust & pet allergies negatif; pollution tidak jelas pengaruhnya	Penerapan Metode MLP dan Fitur yang digunakan
4.	Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu Oleh Gulo & Lubis, (2024)	Multilayer Perceptron (MLP)	Dari 386 sampel: 152 mampu, 86 cukup mampu, 148 kurang mampu; Arsitektur 3-5-1; akurasi 96,9%, recall 92%, presisi 98,5%, F-score 94,9%	Objek penelitian dataset indikasi asma
5.	Predicting emergency department utilization among children with asthma using deep learning models Oleh AlSaad dkk., (2022)	BiLSTM (Bidirectional Long Short-Term Memory), BiGRU (Bidirectional Gated Recurrent Unit), RETAIN	Semua model RNN unggul 4–5% dibandingkan Multinomial Logistic Regression, menunjukkan efektivitas pemodelan temporal dari RNN.	Metode algoritma MLP dan dataset indikasi asma

No.	Penulis	Metode	Hasil	Perbedaan Penelitian
		(Reverse Time Attention Model), Baseline: Multinomial Logistic Regression (MLR)	Multinomial Regression 81% RETAIN 85% BILSTM 85% BIGRU 85%	
6.	A Prognostic Model to Improve Asthma Prediction Outcomes Using Machine Learning Oleh Pooja M.R. dkk., (2024)	Logistic Regression, Support Vector Machine (SVM), Naive Bayes	Hasil dari membandingkan 3 model: Logistik regression 84% SVM 83.4% Naive bayes 85% jadi Model Naive Bayes dengan fitur teroptimisasi menunjukkan performa terbaik	Metode algoritma MLP dan dataset indikasi asma
7.	Deep learning prediction of hospital readmissions for asthma and COPD Oleh Lopez dkk., (2023)	Model Random forest, naive bayes, SVM, GBT, MLP	Hasil nya MLP memiliki akurasi terbaik dengan 79% di asma dan 84% di COPD	Dataset dan konfigurasi MLP
8.	Prediction of Asthma Disease Using Machine Learning Algorithm Oleh Zahab kk.,(2025)	Decision Tree, K-NN, Random Forest, Naïve Bayes, SMOTE	Decision Tree memberikan akurasi terbaik 97,65%; K-NN 97,50%; Random Forest memiliki akurasi tinggi	Metode MLP
9.	Development of childhood asthma prediction models using machine learning approaches Oleh Kothalawala dkk., (2021)	Support Vector Machine (SVM)	Model ML memprediksi asma pada usia sekolah dan pra-sekolah dengan performa lebih baik daripada model sebelumnya mendapatkan akurasi 83%	Metode algoritma MLP dan dataset indikasi asma
10.	AI-Driven Data Analysis for Asthma Risk Prediction Oleh Chen dkk., (2025)	Decision Tree, Random Forest, Gradient Boosted Decision Tree (GBDT), Support Vector Machine (SVM), Artificial Neural Network (ANN), Convolutional Neural Network (CNN, AlexNet), Long Short-Term Memory (LSTM)	Model dibagi 3: High-pitch: Decision Tree – Akurasi 98.66%, Normal-pitch: LSTM – Akurasi 76.94%, Low-pitch: LSTM – Akurasi 85.64%	Metode algoritma MLP dan dataset indikasi asma

2.2 Asma

Asma adalah penyakit inflamasi kronis pada saluran pernapasan yang ditandai dengan hipereaktivitas bronkus. Kondisi ini merupakan salah satu penyakit tidak menular yang paling umum di dunia dan dapat menjadi sangat berbahaya. Tanpa diagnosis dan manajemen yang tepat, asma dapat menyebabkan serangan akut (eksaserbasi) yang parah, yang ditandai dengan penyempitan saluran napas hebat, sehingga berpotensi mengancam jiwa. Memprediksi risiko asma dan pola serangannya secara dini sangat penting untuk intervensi proaktif dan meningkatkan kualitas hidup pasien. Gejala awalnya sering berupa batuk (terutama malam hari), mengi (napas berbunyi), sesak dada, dan kesulitan bernapas. Penyakit ini umumnya dipicu oleh kombinasi faktor genetik dan paparan lingkungan, seperti alergen (debu, serbuk sari), polusi udara, dan infeksi saluran napas (Agache et al., 2021).

Pemahaman modern tentang asma mengungkapkan bahwa ia bukanlah sebuah penyakit tunggal, melainkan sebuah sindrom heterogen dengan berbagai manifestasi (Kuruvilla et al., 2019). Secara tradisional, asma diklasifikasikan berdasarkan tingkat keparahan dan frekuensi gejalanya, yang menentukan pendekatan penanganan awal, sebagaimana yang dipaparkan dalam pedoman GINA (2024). Klasifikasi ini berkisar dari asma intermiten (gejala jarang, kurang dari dua kali seminggu) hingga asma persisten yang dibagi lagi menjadi ringan, sedang, dan berat, di mana gejala yang sering dan gangguan tidur menjadi lebih lazim, serta fungsi paru yang semakin menurun. Lebih mendalam lagi, asma dapat dikategorikan berdasarkan fenotipe imunologisnya, yang mencerminkan mekanisme penyakit yang mendasarinya. Fenotipe Th2-high (eosinofilik) ditandai

dengan peradangan yang dipimpin oleh sel T helper 2, yang melibatkan peningkatan sel imun seperti eosinofil dan produksi imunoglobulin E (IgE). Fenotipe ini sering merespons sangat baik terhadap kortikosteroid inhalasi. Sebaliknya, fenotipe Th2-low (non-eosinofilik) melibatkan jalur peradangan yang berbeda, sering kali terkait dengan neutrofil atau sel-sel imun lain, dan umumnya lebih resisten terhadap terapi steroid konvensional (Kuo et al., 2021). Selain dua fenotipe utama tersebut, terdapat beberapa subfenotipe klinis yang penting untuk dikenali. Exercise-induced bronchoconstriction (EIB) mengacu pada penyempitan saluran napas yang terjadi setelah aktivitas fisik (Bonini & Silvers, 2021). Asma okupasional secara langsung disebabkan oleh paparan debu, gas, uap, atau bahan kimia di tempat kerja. Sementara asma alergi dipicu oleh paparan alergen lingkungan, asma non-alergi dapat dipicu oleh infeksi, cuaca dingin, atau stres, tanpa melibatkan mekanisme alergi yang khas.

Kemunculan dan perjalanan penyakit asma dipicu oleh interaksi yang rumit antara kerentanan genetik individu dan paparan lingkungan. Dari sisi genetik, adanya predisposisi herediter, terutama riwayat atopi dalam keluarga, sangat meningkatkan risiko. Kerentanan ini sering diperkuat oleh adanya polimorfisme pada gen-gen yang mengatur respons imun, dan mekanisme epigenetik seperti metilasi DNA dapat menjelaskan bagaimana paparan lingkungan memodulasi ekspresi gen-gen ini (Jeong et al., 2022). Faktor lingkungan kemudian bertindak sebagai pemicu yang "menghidupkan" kerentanan genetik ini. Paparan alergen dalam ruangan (seperti tungau debu rumah) dan luar ruangan (seperti serbuk sari) adalah pemicu utama. Selain itu, polutan udara seperti asap rokok dan asap

kendaraan bermotor dapat mengiritasi saluran napas dan memicu peradangan. Infeksi virus saluran pernapasan pada masa kanak-kanak, khususnya oleh Respiratory Syncytial Virus (RSV) dan rhinovirus, tidak hanya dapat memicu episode mengi akut tetapi juga dikaitkan dengan peningkatan risiko berkembangnya asma yang menetap di kemudian hari (Jartti & Gern, 2020). Gaya hidup juga memainkan peran yang semakin diakui. Obesitas dapat memperburuk asma melalui mekanisme peradangan sistemik dan beban mekanis pada dada (Peters et al., 2021). Diet rendah antioksidan dapat mengurangi pertahanan alami tubuh terhadap stres oksidatif di saluran napas. Tidak kalah pentingnya, stres psikologis kronis dapat memodulasi sistem kekebalan tubuh dan meningkatkan frekuensi kekambuhan gejala asma.

Menegakkan diagnosis asma yang akurat memerlukan pendekatan yang komprehensif dan multidimensi, karena tidak ada satu pun tes yang definitif, sebagaimana ditekankan dalam pedoman GINA (2024). Langkah pertama selalu melibatkan pengambilan riwayat medis yang sangat mendetail dan pemeriksaan tanda-tanda klinis yang sugestif. Untuk mengonfirmasi kecurigaan klinis, serangkaian pemeriksaan fungsi paru dilakukan. Spirometri adalah yang terpenting, digunakan untuk mendeteksi adanya hambatan aliran udara. Uji reversibilitas bronkodilator kemudian dilakukan; peningkatan FEV1 yang signifikan ($\geq 12\%$ dan 200 mL) setelah menghirup bronkodilator mengonfirmasi adanya penyempitan saluran napas yang reversibel. Untuk pemantauan harian di rumah, pengukuran Peak Expiratory Flow (PEF) dapat digunakan untuk menilai variabilitas aliran udara. Pada kasus dengan gejala yang khas namun hasil

spirometri normal, tes provokasi bronkus (seperti methacholine challenge test) dapat dilakukan untuk mengungkap adanya hiperreaktivitas saluran napas (Coates et al., 2021). Selain tes fungsi, pengukuran biomarker peradangan semakin populer. Pemeriksaan Fraksi Nitrik Oksida Ekshalasi (FeNO) merupakan alat yang tidak invasif untuk mengukur kadar nitrik oksida di napas, yang mencerminkan tingkat peradangan eosinofilik di saluran napas dan dapat memandu terapi, terutama untuk fenotipe Th2-high (Heaney et al., 2020).

2.3 Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) adalah arsitektur fundamental dalam deep learning dan merupakan salah satu jenis feedforward artificial neural network (ANN) yang paling umum digunakan. Strukturnya terdiri dari setidaknya tiga lapisan node: satu lapisan input (input layer), satu atau lebih lapisan tersembunyi (hidden layers), dan satu lapisan output (output layer). Kekuatan utama MLP terletak pada kemampuannya untuk mempelajari dan memodelkan hubungan yang sangat kompleks dan non-linear dalam data, suatu kemampuan yang seringkali tidak dimiliki oleh algoritma machine learning tradisional yang lebih sederhana (Hussain et al., 2025).

Penelitian yang dilakukan oleh (Daniel et al., 2024) memanfaatkan arsitektur Multilayer Perceptron (MLP) untuk mengembangkan model klasifikasi risiko penyakit jantung. Dalam studi mereka, MLP digunakan untuk menganalisis data pasien yang mencakup 11 fitur kesehatan. Model MLP dilatih untuk mengidentifikasi pola-pola kompleks dari kombinasi berbagai faktor risiko tersebut yang berkontribusi terhadap klasifikasi risiko penyakit jantung. Hasil penelitian

menunjukkan bahwa model MLP mereka mampu mencapai tingkat akurasi, presisi, dan recall yang baik dalam pengujian , membuktikan efektivitasnya sebagai alat bantu untuk deteksi dini risiko penyakit jantung.

Keberhasilan model MLP dalam penelitian (Nimas Ratna Sari & Yulaikha Mar'atullatifah, 2023) tersebut sangat bergantung pada fungsi hidden layers. Lapisan tersembunyi inilah yang memungkinkan MLP untuk memproses sinyal dari lapisan input , mengubah data mentah (karakteristik inti sel) menjadi representasi yang lebih abstrak untuk klasifikasi. Setiap neuron di lapisan ini menerapkan fungsi aktivasi non-linear, seperti "fungsi aktivasi sigmoidal" , yang memungkinkan model untuk "belajar" dan memetakan interaksi kompleks antar 30 variabel input —misalnya, bagaimana 'radius' dan 'tekstur' sel berinteraksi—yang tidak dapat ditangkap oleh model linier. Kemampuan inilah yang membuat MLP menjadi alat yang ampuh untuk tugas klasifikasi dan prediksi di bidang medis, dalam hal ini mengidentifikasi kanker payudara sebagai Malignant (ganas) atau Benign (jinak).

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Prosedur penelitian ini disusun secara sistematis untuk memberikan gambaran menyeluruh mengenai tahapan yang dilakukan dalam proses pembangunan model deteksi penyakit asma berdasarkan data rekam medis menggunakan metode Multi-Layer Perceptron (MLP). Secara umum, prosedur penelitian ini terdiri atas enam tahapan utama: Pengumpulan Data, Desain Sistem, Preprocessing Data, Perancangan Model MLP, Evaluasi Model, dan Skenario Pengujian. Tahap pertama adalah Pengumpulan Data, yang berfokus untuk memperoleh dataset rekam medis pasien yang mencakup variabel klinis dan riwayat yang relevan dengan kondisi asma. Setelah data terkumpul, tahap Desain Sistem dilakukan untuk memodelkan alur proses secara komprehensif, mulai dari data mentah hingga hasil prediksi akhir.

Selanjutnya, Preprocessing Data dilaksanakan untuk memastikan kualitas data agar sesuai dengan kebutuhan algoritma MLP, meliputi proses pembersihan, normalisasi/standarisasi, encoding fitur kategorikal, dan pembagian data latih-uji. Pada tahap ini, kualitas data sangat krusial untuk kinerja model. Setelah data siap, dilakukan Perancangan Model MLP, di mana arsitektur model dibangun dan dilatih (training) menggunakan data latih yang telah diproses. Tahap kelima adalah Evaluasi Model, yang bertujuan untuk menilai performa model yang telah dibangun menggunakan metrik evaluasi akurasi, presisi, recall, dan F1-score. Tahap terakhir

adalah Skenario Pengujian dan Uji Coba, yang melibatkan pengujian berbagai konfigurasi dan hiperparameter model untuk mendapatkan hasil terbaik, serta melakukan evaluasi menyeluruh terhadap kapabilitas sistem dalam mendeteksi penyakit asma. Dengan prosedur penelitian yang terstruktur ini, diharapkan model MLP yang dihasilkan mampu memberikan hasil deteksi kondisi pasien yang akurat dan konsisten.

Seluruh tahapan tersebut dilakukan secara berurutan sebagaimana ditunjukkan pada Gambar 3.1 Dengan prosedur penelitian ini, diharapkan model yang dihasilkan mampu memberikan hasil prediksi kondisi pasien yang akurat dan konsisten terhadap data penyakit asma pada pasien.

3.2 Pengumpulan Data

3.2.1 Experimen Data

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, dengan judul "Asthma Patient Dataset" (Rabie El Kharoua 2024.). Dataset ini merupakan dataset sintetik yang dirancang untuk tujuan penelitian dan edukasi dalam bidang data science dan machine learning, dengan tetap menjaga karakteristik klinis yang relevan untuk studi penyakit asma.

Dataset awal terdiri dari 2.392 baris (pasien) dan 27 kolom (variabel). Namun dalam penelitian ini, hanya 21 variabel yang digunakan berdasarkan relevansi klinis dan tujuan penelitian. Variabel yang digunakan mencakup aspek demografi, gaya hidup, lingkungan, riwayat medis, dan gejala klinis yang berkaitan dengan risiko asma. Variabel target dalam penelitian ini adalah Diagnosis, yang menunjukkan status diagnosis asma (0 = Tidak Asma, 1 = Asma). Terdapat lebih

banyak yang diberi label 0 dibandingkan label 1. Tidak asma mencakup 2268 data, di mana 94,81% dari keseluruhan data memiliki label 0. Sementara itu, asma hanya terdiri dari 124 data, yang berarti hanya 5,18% dari data yang memiliki label 1.

Tabel 3.1 di bawah ini merangkum variabel-variabel yang digunakan dalam penelitian:

Tabel 3.1 Deskripsi Data

No.	Nama Variabel	Tipe Data	Deskripsi	Nilai
1	Age	Numerik	Umur pasien	5–80 tahun
2	Smoking	Kategorik	Status merokok	0 = Tidak, 1 = Ya
3	PhysicalActivity	Numerik	Aktivitas fisik mingguan (jam)	0 – 10 jam
4	PollenExposure	Numerik	Paparan serbuk sari	0 – 10
5	SleepQuality	Numerik	Skor kualitas tidur	4 – 10
6	PollutionExposure	Numerik	Tingkat paparan polusi	0 – 10
7	BMI	Numerik	Body Mass Index	15 – 40
8	DustExposure	Numerik	Tingkat paparan debu	0 – 10
9	PetAllergy	Kategorik	Alergi terhadap hewan peliharaan	0 = Tidak, 1 = Ya
10	FamilyHistoryAsthma	Kategorik	Riwayat asma dalam keluarga	0 = Tidak, 1 = Ya
11	HistoryOfAllergies	Kategorik	Riwayat alergi secara umum	0 = Tidak, 1 = Ya
12	Eczema	Kategorik	Riwayat eksim	0 = Tidak, 1 = Ya
13	HayFever	Kategorik	Riwayat hay fever (rinitis alergi)	0 = Tidak, 1 = Ya
14	GastroesophagealRef lux	Kategorik	Riwayat refluks gastroesofagus	0 = Tidak, 1 = Ya
15	Wheezing	Kategorik	Gejala mengi (<i>wheezing</i>)	0 = Tidak, 1 = Ya
16	ShortnessOfBreath	Kategorik	Gejala sesak napas	0 = Tidak, 1 = Ya
17	ChestTightness	Kategorik	Gejala dada terasa sesak	0 = Tidak, 1 = Ya
18	Coughing	Kategorik	Gejala batuk	0 = Tidak, 1 = Ya
19	LungFunctionFEV1	Numerik	Volume Ekspirasi Paksa dalam 1 detik (FEV1)	1,0 - 4,0
20	LungFunctionFVC	Numerik	Kapasitas Vital Paksa (FVC)	1,0 - 4,0
21	Label Diagnosis	Kategorik	Informasi status indikasi asma	0 = Tidak, 1 = Ya

Pemilihan variabel dalam penelitian ini didasarkan pada pertimbangan klinis dan literatur terkait faktor risiko asma. Variabel seperti Age merupakan faktor demografis dasar yang memengaruhi prevalensi asma. BMI, Smoking, PhysicalActivity, DietQuality, dan SleepQuality merepresentasikan faktor gaya

hidup yang telah terbukti berkorelasi dengan kondisi pernapasan (Peters et al., 2021). Variabel lingkungan seperti PollutionExposure, dan DustExposure dipilih karena paparan alergen dan polutan merupakan pemicu umum asma (Agache et al., 2021).

Selain itu, riwayat medis seperti FamilyHistoryAsthma, HistoryOfAllergies, Eczema, HayFever, dan GastroesophagealReflux dimasukkan karena adanya hubungan komorbiditas dan predisposisi genetik terhadap asma (Kuruvilla et al., 2019). Gejala klinis seperti Wheezing, ShortnessOfBreath, ChestTightness, Coughing, NighttimeSymptoms, dan ExerciseInduced merupakan indikator langsung yang digunakan dalam kriteria diagnosis asma menurut pedoman GINA (2024).

3.2.2 Augmentasi Data Menggunakan Smote

Untuk mengatasi permasalahan ketidakseimbangan distribusi kelas pada dataset, diterapkan metode SMOTE (*Synthetic Minority Over-sampling Technique*). Ketidakseimbangan kelas dapat menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan pola pada kelas minoritas. Oleh karena itu, SMOTE digunakan untuk menghasilkan sampel sintetis baru pada kelas minoritas berdasarkan interpolasi antar sampel yang berdekatan dalam ruang fitur. Secara matematis, pembentukan data sintetis pada SMOTE dapat dinyatakan sebagai berikut:

$$S_{\text{new}} = S_i + \lambda \times (\hat{S}_i - S_i) \quad 3.1$$

Keterangan:

S_{new} = Data sintetis baru yang dihasilkan Smote

S_i = Sampel data dari kelas minoritas

λ = Bilangan acak dalam rentang (0, 1)

$\hat{S}_i$ = Salah satu tetangga terdekat (*nearest neighbor*) dari S_i

di mana S_i merupakan sampel dari kelas minoritas, $\hat{S}_i$ adalah salah satu tetangga terdekatnya, dan λ adalah bilangan acak antara 0 dan 1. Dengan pendekatan ini, data baru yang dihasilkan bukan sekadar duplikasi, melainkan representasi sintetis yang memperkaya variasi pada kelas minoritas.


Penerapan SMOTE dalam penelitian ini dilakukan hanya pada data pelatihan (training data) setelah proses pembagian dataset. Hal ini bertujuan untuk menghindari terjadinya data leakage yang dapat menyebabkan hasil evaluasi menjadi bias. Dengan tahapan pra-pemrosesan yang sistematis ini, dataset diharapkan berada dalam kondisi optimal sebelum memasuki tahap pemodelan menggunakan Multilayer Perceptron.

3.3 Desain Sistem

Desain sistem dalam penelitian ini menggambarkan keseluruhan alur proses pengolahan data yang dilakukan secara sistematis, dimulai dari tahap pra-pemrosesan hingga menghasilkan output berupa klasifikasi kondisi pasien ke dalam kategori sehat atau tidak sehat (asma). Perancangan sistem ini bertujuan untuk memastikan bahwa setiap tahapan yang dilakukan memiliki keterkaitan yang jelas dan terstruktur, sehingga proses pembangunan model dapat berjalan secara terarah dan sesuai dengan tujuan penelitian.

ditunjukkan pada Gambar 3.2 Diagram tersebut merepresentasikan tahapan-tahapan utama yang dilakukan dalam penelitian ini, mulai dari data mentah yang diperoleh, proses pembersihan dan transformasi data, penanganan

ketidakseimbangan kelas menggunakan metode SMOTE, hingga proses pembelajaran menggunakan algoritma Multilayer Perceptron dan menghasilkan prediksi akhir. Dengan adanya diagram alir tersebut, alur kerja sistem dapat dipahami secara konseptual sebelum masuk ke pembahasan teknis dan matematis.



Gambar 3. 1 Desain Sistem

3.3.1 Pra-Pemrosesan Data

Pra-pemrosesan (preprocessing) data merupakan tahapan krusial dalam mempersiapkan dataset sebelum memasuki proses pelatihan model. Tahap ini bertujuan untuk memastikan bahwa data yang digunakan memiliki kualitas yang baik, bebas dari inkonsistensi, serta berada dalam format yang sesuai untuk diproses oleh model klasifikasi berbasis jaringan saraf tiruan. Dalam penelitian ini, beberapa langkah pra-pemrosesan diterapkan untuk mengoptimalkan performa model Multilayer Perceptron (MLP).

Langkah pertama yang dilakukan adalah pembersihan data (data cleaning). Proses ini mencakup pemeriksaan terhadap nilai yang hilang (missing value), data duplikat, serta ketidaksesuaian tipe data pada setiap atribut. Data yang memiliki nilai kosong ditangani dengan metode tertentu, seperti penghapusan baris data atau pengisian nilai menggunakan pendekatan statistik yang relevan. Penghapusan data duplikat juga dilakukan untuk mencegah bias dalam proses pelatihan model. Tahap ini penting untuk memastikan bahwa model tidak mempelajari pola dari data yang keliru atau tidak representatif.

Selanjutnya, dilakukan transformasi data agar seluruh atribut dapat diproses oleh model jaringan saraf. Variabel kategorikal dikonversi ke dalam bentuk numerik melalui proses encoding. Transformasi ini diperlukan karena model neural network hanya dapat menerima input berupa nilai numerik. Dengan mengubah data kategorikal menjadi representasi numerik yang sesuai, informasi yang terkandung dalam atribut tetap terjaga tanpa mengubah makna aslinya.

Selain itu, dilakukan normalisasi terhadap atribut numerik menggunakan metode Min-Max Scaling. Normalisasi ini bertujuan untuk menyamakan rentang nilai antar fitur sehingga tidak terjadi dominasi fitur tertentu dalam proses pembelajaran model. Metode Min-Max Scaling mengubah nilai asli ke dalam rentang $[0,1]$ menggunakan persamaan berikut:

$$X = \frac{S_{\text{new}} - S_{\text{min}}}{S_{\text{max}} - S_{\text{min}}} \quad 3.2$$

Keterangan:

X = Nilai hasil Normalisasi
 S_{new} = Nilai asli dari fitur (Hasil Smote)
 S_{min} = Nilai minimum fitur
 S_{max} = Nilai maximum fitur

persamaan tersebut, setiap nilai pada suatu fitur ditransformasikan berdasarkan nilai minimum dan maksimum pada fitur tersebut. Proses ini membantu meningkatkan stabilitas pelatihan serta mempercepat konvergensi model, karena jaringan saraf sensitif terhadap perbedaan skala input.

3.3.2 Arsitektur Multilayer Perceptron

Pada tahapan perancangan model, Multilayer Perceptron (MLP) digunakan sebagai metode klasifikasi untuk menentukan kondisi pasien ke dalam dua kategori, yaitu sehat dan tidak sehat (asma). Model ini dipilih karena kemampuannya dalam mempelajari pola kompleks antar fitur. Model ini merupakan jaringan saraf tiruan bertipe *feedforward*, di mana aliran informasi bergerak secara satu arah dari lapisan input menuju lapisan output tanpa adanya umpan balik.

Struktur jaringan yang dibangun terdiri atas satu lapisan input (*input layer*), dua lapisan tersembunyi (*hidden layer*), dan satu lapisan output (*output layer*). Setiap lapisan memiliki fungsi transformasi tertentu yang secara bertahap mengubah representasi data hingga menghasilkan keputusan akhir dalam bentuk probabilitas.

Lapisan input berfungsi menerima seluruh fitur hasil tahap pra-pemrosesan data. Nilai pada lapisan ini kemudian diteruskan menuju hidden layer pertama untuk dilakukan proses transformasi linier melalui perkalian bobot dan penambahan bias. Proses inilah yang menjadi awal dari tahapan *feedforward propagation* dalam jaringan MLP.

Arsitektur jaringan yang digunakan terdiri dari tiga komponen utama, yaitu lapisan input (*input layer*), dua lapisan tersembunyi (*hidden layer*), dan satu lapisan output (*output layer*), sebagaimana ditunjukkan pada Gambar 3.3. Setiap neuron pada suatu lapisan terhubung dengan seluruh neuron pada lapisan berikutnya:


1. Input Layer: terdiri dari 20 neuron yaitu Age, Smoking, PhysicalActivity, PollenExposure, SleepQuality,

PollutionExposure, BMI, DustExposure, PetAllergy, FamilyHistoryAsthma, HistoryOfAllergies, Eczema, HayFever, GastroesophagealReflux, Wheezing, ShortnessOfBreath, ChestTightness, Coughing, LungFunctionFEV1, LungFunctionFVC. Setiap neuron pada input layer merepresentasikan satu fitur, tanpa melakukan transformasi, dan kemudian meneruskan nilainya ke hidden layer.

2. Hidden Layer: berfungsi untuk melakukan transformasi awal terhadap data melalui kombinasi bobot (weight) dan bias pada setiap neuron. Pada tahap ini, jaringan mulai mempelajari pola hubungan antar fitur yang tidak dapat terlihat secara langsung pada data. Jumlah neuron pada lapisan ini ditentukan berdasarkan hasil perancangan model yang bertujuan untuk memperoleh keseimbangan antara kompleksitas dan performa.
3. Output Layer: terdiri atas satu neuron dengan fungsi aktivasi sigmoid. Lapisan ini bertugas menghasilkan nilai probabilitas tunggal yang merepresentasikan kemungkinan suatu data termasuk ke dalam kelas target, yaitu sehat (0) atau tidak sehat (1). Nilai probabilitas tersebut kemudian digunakan sebagai dasar dalam menentukan hasil klasifikasi akhir.

Meskipun jumlah neuron pada lapisan tersembunyi ditentukan berdasarkan hasil perancangan model, seluruh konfigurasi jaringan dalam penelitian ini secara konsisten menggunakan fungsi aktivasi Rectified Linear Unit (ReLU) pada kedua

hidden layer. Penerapan fungsi aktivasi ReLU bertujuan untuk meningkatkan efisiensi komputasi serta mengurangi risiko terjadinya masalah vanishing gradient pada saat proses pelatihan. Dengan karakteristik fungsi yang sederhana dan tidak bersifat jenuh pada nilai positif, ReLU memungkinkan model untuk mempelajari pola data secara lebih stabil dan efektif, khususnya dalam menangkap hubungan non-linear antar fitur yang berkaitan dengan kondisi asma.



Gambar 3.2 Arsitektur *Multilayer Perceptron*(MLP)

A. Tahapan Feedforward Propagation

Proses *feedforward propagation* pada jaringan Multilayer Perceptron (MLP) merupakan tahap perhitungan maju yang dimulai dari lapisan input hingga menghasilkan prediksi pada lapisan output. Pada tahap ini, setiap neuron menerima nilai masukan, kemudian mengalikannya dengan bobot (*weight*) yang terhubung,

menambahkan nilai bias (*bias*), dan memproses hasilnya menggunakan fungsi aktivasi. Output dari satu lapisan akan menjadi input bagi lapisan berikutnya secara berurutan hingga mencapai lapisan output yang menghasilkan prediksi akhir model. Sebelum proses feedforward dilakukan, data yang digunakan dalam penelitian ini telah melalui tahap pra-pemrosesan. Dengan demikian, data yang masuk ke jaringan telah berada pada rentang yang seragam dan siap untuk diproses oleh model MLP.

Fungsi aktivasi memiliki peran penting dalam memperkenalkan sifat non-linearitas pada jaringan saraf tiruan. Tanpa fungsi aktivasi, jaringan hanya akan bekerja sebagai model linier dan tidak mampu mempelajari pola kompleks dalam data.

Pada lapisan tersembunyi, penelitian ini menggunakan fungsi aktivasi Rectified Linear Unit (ReLU). ReLU bekerja dengan memberikan keluaran nol untuk input bernilai negatif dan mempertahankan nilai input jika bernilai positif. Secara matematis, fungsi ReLU dirumuskan sebagai berikut:

Penggunaan ReLU membantu mempercepat proses konvergensi serta mengurangi permasalahan *vanishing gradient* pada jaringan dengan lebih dari satu hidden layer.

Tahap pertama feedforward dimulai dari lapisan input menuju hidden layer pertama. Setiap nilai input X_i dikalikan dengan bobot yang menghubungkannya ke neuron pada hidden layer pertama, kemudian dijumlahkan dan ditambahkan bias. Secara matematis dirumuskan sebagai berikut:

$$U_j = \sum_{i=1}^n W_{i,j} \cdot X + b_j \quad 3.4$$

Keterangan :

U_j : nilai pre-aktivasi neuron ke- j pada hidden layer 1

$W_{i,j}$: bobot yang menghubungkan input ke- i ke- j pada hidden layer 1

X : nilai input

b_j : bias neuron ke- j pada hidden layer 1

Hasil kombinasi linier tersebut kemudian diproses menggunakan fungsi aktivasi ReLU:

$$\hat{U}_j = ReLU(U_{(j)}) \quad 3.5$$

Output dari hidden layer pertama selanjutnya menjadi input bagi hidden layer kedua. Proses perhitungan dilakukan dengan cara yang serupa, yaitu:

$$V_k = \sum_{j=1}^J N_{j,k} \cdot \hat{U}_j + c_k \quad 3.6$$

Keterangan :

V_k : nilai pre-aktivasi neuron ke- k pada hidden layer 2

$N_{j,k}$: bobot neuron ke- j hidden layer 1 dengan neuron ke- k hidden layer 2

$\hat{U}_j$: nilai output neuron ke- j dari hidden layer 1

c_k : bias neuron ke- k pada hidden layer 2

Kemudian diproses melalui fungsi aktivasi ReLU:

$$\hat{V}_k = ReLU(V_{(k)}) \quad 3.7$$

Karena penelitian ini bertujuan untuk melakukan klasifikasi biner dalam mendeteksi kondisi asma (sehat dan tidak sehat), maka pada lapisan output digunakan satu neuron. Proses pada lapisan output diawali dengan melakukan transformasi linier terhadap seluruh output dari hidden layer kedua. Setiap nilai V_k dikalikan dengan bobot yang terhubung ke neuron output, kemudian dijumlahkan

dan ditambahkan bias. Secara matematis, proses tersebut dirumuskan sebagai berikut:

$$Y_l = \sum_{k=1}^K M_{k,l} \cdot \hat{V}_k + d_y \quad 3.8$$

$$\hat{p} = \sigma(Y_l) = \frac{1}{1 + e^{-Y_l}}$$

Keterangan :

Y_l : nilai pre-aktivasi pada lapisan output (kombinasi linier)

$M_{k,l}$: bobot neuron ke- k hidden layer 2 dengan neuron output

$\hat{V}_k$: nilai output neuron ke- k dari hidden layer 2

d_y : bias pada lapisan output

p : probabilitas prediksi hasil fungsi sigmoid

σ : fungsi aktivasi sigmoid

Nilai y_l tersebut masih berupa nilai linier dan belum merepresentasikan probabilitas. Oleh karena itu, diperlukan fungsi aktivasi untuk memetakan nilai tersebut ke dalam rentang 0 hingga 1.

Nilai $\hat{p}$ yang diperoleh merupakan hasil akhir dari proses feedforward propagation dan merepresentasikan probabilitas suatu data termasuk dalam kategori asma. Nilai ini selanjutnya digunakan pada tahap perhitungan fungsi loss untuk mengukur tingkat kesalahan prediksi sebelum dilakukan proses backpropagation guna memperbarui bobot jaringan.

B. Fungsi Rugi(Loss)

Pada permasalahan klasifikasi biner untuk mendeteksi kondisi pasien (sehat dan tidak sehat/asma), fungsi rugi yang digunakan adalah Binary Cross Entropy (BCE). Pemilihan BCE didasarkan pada kesesuaiannya dengan fungsi aktivasi sigmoid pada lapisan output, yang menghasilkan nilai probabilitas dalam rentang 0

hingga 1. Fungsi ini secara langsung membandingkan probabilitas prediksi model dengan label target biner (0 atau 1).

Tujuan dari fungsi rugi ini adalah untuk mengukur tingkat kesalahan prediksi model pada data pelatihan, serta memantau performa model pada data validasi guna mencegah terjadinya overfitting. Secara matematis, fungsi Binary Cross Entropy untuk seluruh data pelatihan dirumuskan sebagai berikut:

$$BCE(y, \hat{p}) = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{p}_i) + (1 - y_i) \log(1 - \hat{p}_i)) \quad 3.11$$

Keterangan:

N : jumlah sampel data

y_i : label sebenarnya untuk sampel ke-i (0 = sehat, 1 = asma)

$\hat{p}_i$: probabilitas prediksi model bahwa sampel ke-i termasuk kelas asma

Nilai probabilitas $\hat{y}_i$ yang diperoleh dari lapisan output sebelumnya dimasukkan ke dalam fungsi Binary Cross Entropy untuk menghitung kesalahan prediksi. Untuk satu sampel data ($N = 1$), persamaan tersebut dapat disederhanakan menjadi:

$$BCE(y, \hat{p}) = -[y \log(\hat{p}) + (1 - y) \log(1 - \hat{p})] \quad 3.12$$

Apabila label target $y = 1$ (pasien terindikasi asma), maka fungsi menjadi:

$$BCE(1, \hat{p}) = -\log(\hat{p}) \quad 3.13$$

Sedangkan apabila label target $y = 0$ (pasien sehat), maka fungsi menjadi:

$$BCE(0, \hat{p}) = -\log(1 - \hat{p}) \quad 3.14$$

Hal ini menunjukkan bahwa model akan memperoleh penalti besar apabila probabilitas prediksi jauh dari label sebenarnya. Semakin dekat nilai $\hat{y}$ terhadap nilai target, maka nilai loss yang dihasilkan akan semakin kecil.

Pemilihan BCE juga dinilai lebih sesuai dibandingkan Mean Squared Error (MSE) pada tugas klasifikasi, karena BCE lebih sensitif terhadap kesalahan prediksi probabilistik. Dengan demikian, gradien yang dihasilkan menjadi lebih informatif, sehingga proses pelatihan model cenderung lebih stabil dan lebih cepat mencapai konvergensi.

Dalam implementasinya, nilai BCE dihitung pada data pelatihan untuk memperbarui bobot dan bias melalui proses backpropagation, serta dipantau pada data validasi untuk mendeteksi kemungkinan terjadinya overfitting selama proses pelatihan model.

C. Tahapan Backpropagation

Backpropagation digunakan untuk menghitung gradien fungsi Loss terhadap setiap bobot dan bias pada jaringan, kemudian memperbarui parameter tersebut agar nilai Loss semakin menurun dari epoch ke epoch. Proses ini dilakukan pada setiap mini-batch data dan diulang hingga memenuhi kriteria penghentian pelatihan.

Pada penelitian ini, digunakan fungsi aktivasi sigmoid pada lapisan output dan fungsi Loss Binary Cross Entropy (BCE). Kombinasi sigmoid dan BCE menghasilkan bentuk turunan yang lebih sederhana. Jika $\hat{y}$ merupakan probabilitas keluaran model dan y adalah label sebenarnya (0 = sehat, 1 = asma), maka error pada neuron output dirumuskan sebagai:

$$\delta = p - y \quad 3.15$$

Nilai $\delta^{(3)}$ ini merepresentasikan selisih antara probabilitas prediksi dan label sebenarnya, serta menjadi dasar propagasi error ke lapisan sebelumnya.

Error pada hidden layer kedua dihitung dengan “menarik” error dari lapisan output melalui bobot yang terhubung, kemudian dikalikan dengan turunan fungsi aktivasi ReLU. Secara matematis dirumuskan sebagai:

$$\delta_k = M_{kl} \cdot \delta \cdot ReLU'(V_k) \quad 3.16$$

Selanjutnya, error pada *hidden layer* pertama diperoleh dari hasil propagasi error *hidden layer* kedua yang dikalikan dengan turunan fungsi aktivasi ReLU pada lapisan tersebut, yaitu:

$$\delta_j = \sum_{k=1}^K N_{jk} \cdot \delta_k \cdot ReLU'(U_j) \quad 3.17$$

Setelah seluruh nilai error pada masing-masing lapisan diperoleh, langkah berikutnya adalah menghitung gradien. Gradien dihitung berdasarkan aktivasi masukan ke suatu lapisan dan error pada lapisan tersebut.

Gradien pada bobot dan bias lapisan output (Hidden 2 $\rightarrow$ Output) dirumuskan sebagai:

$$\frac{\partial L}{\partial M_{kl}} = V_k \cdot \delta \quad 3.18$$

$$\frac{\partial L}{\partial d_y} = \delta^{(out)} \quad 3.19$$

Selanjutnya, gradien pada *hidden layer* kedua (Hidden 1 → Hidden 2) dihitung sebagai:

$$\frac{\partial L}{\partial N_{j\ k}} = U_j \cdot \delta \quad 3.20$$

3.21

$$\frac{\partial L}{\partial c_k} = \delta_k$$

Adapun gradien pada *hidden layer* pertama (Input → Hidden 1) dirumuskan sebagai:

$$\frac{\partial L}{\partial W_{i\ j}} = X_i \cdot \delta_j \quad 3.22$$

$$\frac{\partial L}{\partial b_j} = \delta_j$$

Setelah seluruh gradien diperoleh, parameter jaringan diperbarui menggunakan *learning rate* α dengan aturan pembaruan sebagai berikut:

$$W_{i\ j} = W_{i\ j} - \alpha \frac{\partial L}{\partial W_{i\ j}} \quad 3.23$$

$$b_j = b_j - \alpha \frac{\partial L}{\partial b_j} \quad 3.24$$

Proses ini dilakukan secara berulang pada setiap mini-batch dalam satu epoch. Selama pelatihan, nilai Loss pada data validasi dipantau untuk menerapkan

mekanisme early stopping guna mencegah overfitting dan memastikan model tidak mengalami penurunan performa generalisasi.

D. Aturan Keputusan (Threshold)

Pada penelitian ini, lapisan output menggunakan fungsi aktivasi sigmoid yang menghasilkan nilai probabilitas dalam rentang 0 hingga 1. Nilai keluaran tersebut dinyatakan sebagai:

$$p = \sigma(y) \quad 3.25$$

dengan p merupakan probabilitas prediksi model terhadap kelas positif (asma), dan y adalah nilai linear combination pada lapisan output sebelum aktivasi.

Karena nilai $\hat{y}$ berbentuk probabilitas kontinu, maka diperlukan suatu aturan keputusan (decision rule) untuk mengonversi nilai tersebut menjadi label kelas biner. Dalam klasifikasi biner, proses ini dilakukan dengan menggunakan ambang batas (threshold).

Pada penelitian ini digunakan nilai threshold sebesar 0,5. Secara matematis, aturan keputusan dirumuskan sebagai berikut:

$$\hat{y} = \begin{cases} 1 & p \geq 0.5 \\ 0 & p < 0.5 \end{cases} \quad 3.26$$

Keterangan:

$\hat{y}$: label kelas hasil keputusan akhir (1 = asma, 0 = tidak asma)
 p : probabilitas prediksi dari lapisan output
 0,5 : nilai ambang batas (threshold)

Dengan demikian, apabila probabilitas prediksi lebih besar atau sama dengan 0,5 maka sampel diklasifikasikan sebagai penderita asma. Sebaliknya,

apabila probabilitas kurang dari 0,5 maka sampel diklasifikasikan sebagai tidak menderita asma.

3.4 Implementasi

Bagian implementasi menerjemahkan seluruh rumus matematis yang telah dirancang pada Bab 3.3 ke dalam bentuk pseudocode yang dapat dipahami secara algoritmik. Terdapat empat komponen utama yang diimplementasikan, yaitu: Feedforward Propagation, Fungsi Rugi (Loss), Backpropagation, dan Aturan Keputusan (Threshold).

Feedforward propagation adalah proses perhitungan maju di mana data mengalir dari lapisan input menuju lapisan output secara berurutan tanpa umpan balik. Proses ini terdiri atas tiga tahap sesuai arsitektur jaringan yang dibangun.

```
No    Pseudocode Hidden layer 1
      function hidden_layer1(X, W, b, J):
        for j = 1 to J:
          U[j] = 0
          for i = 1 to n:
            U[j] = U[j] + (W[i][j] * X[i])
          U[j] = U[j] + b[j]

          // ReLU (Rumus 3.5)
          if U[j] > 0:
            U[j] = U[j]
          else:
            U[j] = 0
        return U
```

Hidden Layer 1 menerima input fitur X, kemudian setiap neuron ke-j menghitung kombinasi linier seluruh input dikalikan bobot ditambah bias (Rumus 3.4). Hasil tersebut langsung diproses oleh fungsi aktivasi ReLU (Rumus 3.5), yaitu jika nilainya positif maka dipertahankan, jika negatif maka diubah menjadi nol. Hal

ini bertujuan agar jaringan mampu menangkap hubungan non-linear antar fitur sekaligus menghindari masalah *vanishing gradient*.

```
No      Pseudocode Hidden layer 2
function hidden_layer2(U, N, c, K):
  for k = 1 to K:
    V[k] = 0
    for j = 1 to J:
      V[k] = V[k] + (N[j][k] * U[j])
    V[k] = V[k] + c[k]

    // ReLU (Rumus 3.7)
    if V[k] > 0:
      V[k] = V[k]
    else:
      V[k] = 0
  return V
```

SHidden Layer 2 menerima output dari hidden layer 1 sebagai inputnya.

Proses yang dilakukan identik: kombinasi linier dengan bobot dan bias baru (Rumus 3.6), kemudian diaktivasi dengan ReLU (Rumus 3.7). Lapisan ini berfungsi mengekstraksi representasi yang lebih abstrak dari data.

```
No      Pseudocode output layer
function output_layer(V, M, dy):
  for l = 0 to 1:
    Y[l] = 0
    for k = 1 to K:
      Y[l] = Y[l] + (M[k][l] * V[k])
    Y[l] = Y[l] + dy[l]
  return Y
function output_layer(V, M, dy):
  for l = 0 to 1:
    Y[l] = 0
    for k = 1 to K:
      Y[l] = Y[l] + (M[k][l] * V[k])
    Y[l] = Y[l] + dy[l]
```

Output Layer menerima output dari hidden layer 2. Pada lapisan ini dilakukan transformasi linier terlebih dahulu (Rumus 3.8), kemudian hasilnya dilewatkan ke fungsi aktivasi sigmoid yang mengubah nilai linier tersebut menjadi

probabilitas dalam rentang 0 hingga 1. Nilai probabilitas inilah yang menjadi dasar keputusan klasifikasi apakah pasien terindikasi asma atau tidak.

Setelah proses feedforward menghasilkan nilai probabilitas, langkah berikutnya adalah mengukur seberapa besar kesalahan prediksi model dibandingkan label sebenarnya. Fungsi rugi yang digunakan adalah Binary Cross Entropy (BCE) (Rumus 3.11), yang dipilih karena sesuai dengan karakteristik klasifikasi biner dan berpasangan dengan fungsi aktivasi sigmoid pada lapisan output.

```
No      Pseudocode Binary Cross Entropy
        FUNCTION hitung_BCE(y[], p[], N):
            total_loss = 0

            FOR i = 1 TO N:
                // Kliping numerik agar log tidak -infinity
                p_clip = max(1e-7, min(1 - 1e-7, p[i]))

                // Kontribusi BCE sampel ke-i
                loss_i = y[i] * log(p_clip) + (1 - y[i]) * log(1 - p_clip)
                total_loss = total_loss + loss_i

            BCE = -(1 / N) * total_loss
```

Backpropagation adalah mekanisme untuk memperbarui seluruh bobot dan bias jaringan agar nilai BCE semakin menurun dari epoch ke epoch. Prosesnya dilakukan dalam dua tahap: perhitungan error (gradien) mundur dari output ke input, lalu pembaruan parameter.

```
No      Pseudocode Hitung Error & Gradien
        FUNCTION backpropagation(p, y, V[], Vraw[], U[], Uraw[], X[],
                                M[], N[], W[], b[], c[], dy):

            // ERROR OUTPUT LAYER (Rumus 3.15)
            // Turunan BCE + sigmoid menyederhanakan menjadi: p - y
            delta_out = p - y

            // ERROR HIDDEN LAYER 2 (Rumus 3.16)
            FOR k = 1 TO K:
```

```

No    Pseudocode Hitung Error & Gradien
      relu_deriv_V = IF Vraw[k] > 0 THEN 1 ELSE 0
      delta_H2[k] = M[k] * delta_out * relu_deriv_V

      // ERROR HIDDEN LAYER 1 (Rumus 3.17)
      FOR j = 1 TO J:
        sum_delta = 0
        FOR k = 1 TO K:
          sum_delta = sum_delta + N[j][k] * delta_H2[k]
        relu_deriv_U = IF Uraw[j] > 0 THEN 1 ELSE 0
        delta_H1[j] = sum_delta * relu_deriv_U

      // GRADIEN OUTPUT LAYER (Rumus 3.18 & 3.19)
      FOR k = 1 TO K:
        grad_M[k] = V[k] * delta_out //  $\partial L / \partial M_{\{k,1\}}$ 
      grad_dy = delta_out //  $\partial L / \partial dy$ 

      // GRADIEN HIDDEN LAYER 2 (Rumus 3.20 & 3.21)
      FOR j = 1 TO J:
        FOR k = 1 TO K:
          grad_N[j][k] = U[j] * delta_H2[k] //  $\partial L / \partial N_{\{j,k\}}$ 
      FOR k = 1 TO K:
        grad_c[k] = delta_H2[k] //  $\partial L / \partial c_k$ 

      // GRADIEN HIDDEN LAYER 1 (Rumus 3.22)
      FOR i = 1 TO n:
        FOR j = 1 TO J:
          grad_W[i][j] = X[i] * delta_H1[j] //  $\partial L / \partial W_{\{i,j\}}$ 
      FOR j = 1 TO J:
        grad_b[j] = delta_H1[j] //  $\partial L / \partial b_j$ 

      RETURN grad_W, grad_b, grad_N, grad_c, grad_M, grad_dy

```

Setiap bobot dan bias diperbarui dengan aturan gradient descent (Rumus 3.23–3.24): parameter baru = parameter lama dikurangi learning rate ($\alpha = 0,001$) dikalikan gradiennya. Proses ini diulang untuk setiap mini-batch dalam satu epoch, dengan total maksimum 500 epoch menggunakan optimizer Adam dan batch size 32.

```

No    Pseudocode Pembaruan Bobot
      FUNCTION update_weights(W[], b[], N[], c[], M[], dy, grad_M, grad_dy, alpha)
        grad_W, grad_b, grad_N, grad_c,
        grad_M, grad_dy, alpha)

      // Hidden Layer 1 — bobot & bias
      FOR i = 1 TO n:
        FOR j = 1 TO J:
          W[i][j] = W[i][j] - alpha * grad_W[i][j] // Rumus 3.23

```

```

FOR j = 1 TO J:
    b[j] = b[j] - alpha * grad_b[j]          // Rumus 3.24

// Hidden Layer 2 — bobot & bias
FOR j = 1 TO J:
    FOR k = 1 TO K:
        N[j][k] = N[j][k] - alpha * grad_N[j][k]
    FOR k = 1 TO K:
        c[k] = c[k] - alpha * grad_c[k]

// Output Layer — bobot & bias
FOR k = 1 TO K:
    M[k] = M[k] - alpha * grad_M[k]
    bout = bout - alpha * grad_dy

RETURN W, b, N, c, M, dy

```

Setelah model selesai dilatih dan digunakan untuk memprediksi data uji, lapisan output menghasilkan nilai probabilitas p yang bersifat kontinu (Rumus 3.25). Nilai ini belum bisa langsung diinterpretasikan sebagai label kelas, sehingga diperlukan aturan keputusan.

```

No    Pseudocode Threshold
      FUNCTION hitung_sigmoid(y_linear):
        // Rumus 3.25
        p = 1 / (1 + exp(-y_linear))
        RETURN p

      FUNCTION aturan_keputusan(p, threshold = 0.5):
        // Rumus 3.26
        IF p >= threshold:
            y_hat = 1    // → Asma
        ELSE:
            y_hat = 0    // → Tidak Asma
        RETURN y_hat

      FUNCTION prediksi_batch(X_test[], bobot_terlatih, threshold = 0.5):

        hasil = []

        FOR EACH sampel x IN X_test:

            // Feedforward (Rumus 3.4–3.8)
            U = hidden_layer1(x, W, b, J)
            V = hidden_layer2(U, N, c, K)
            y_lin = output_layer(V, M, bout)

```

```
No      Pseudocode Threshold
        // Aktivasi sigmoid (Rumus 3.25)
        p    = hitung_sigmoid(y_lin)

        // Keputusan threshold (Rumus 3.26)
        label = aturan_keputusan(p, threshold)

        hasil.append({ "probabilitas": p, "label": label })

RETURN hasil
```


BAB IV


HASIL DAN PEMBAHASAN

4.1 Persiapan Data

Pada penelitian ini, dilakukan pengujian model Multilayer Perceptron (MLP) untuk mendeteksi indikasi penyakit asma menggunakan dataset rekam medis. Dataset yang digunakan dalam penelitian ini adalah Asthma Patient Dataset yang diperoleh dari platform Kaggle (Rabie El Kharoua, 2024). Dataset tersebut merupakan dataset sintetik yang dirancang untuk keperluan penelitian dan edukasi di bidang data science dan machine learning, dengan tetap mempertahankan karakteristik klinis yang relevan untuk studi penyakit asma.

Dataset awal terdiri dari 2.392 baris data pasien dan 29 kolom variabel. Dalam penelitian ini, digunakan sebanyak 21 variabel yang dipilih berdasarkan relevansi klinis, meliputi aspek demografi, gaya hidup, lingkungan, riwayat medis, dan gejala klinis yang berkaitan dengan risiko asma. Variabel target dalam penelitian ini adalah Diagnosis, yang merepresentasikan status diagnosis asma dengan dua nilai, yaitu 0 (Tidak Asma) dan 1 (Asma).

Distribusi kelas pada dataset ini menunjukkan ketidakseimbangan yang sangat signifikan. Kelas non-asma (label 0) berjumlah 2.268 data atau sebesar 94,82% dari keseluruhan data, sedangkan kelas asma (label 1) hanya berjumlah 124 data atau sebesar 5,18% dari keseluruhan data. Kondisi ketidakseimbangan distribusi kelas tersebut dapat dilihat pada Gambar 4.1.



Gambar 4.1 Dataset Kelas Asma


Berdasarkan Gambar 4.1 terlihat bahwa distribusi kelas pada dataset sangat tidak seimbang, di mana kelas non-asma mendominasi secara signifikan dengan jumlah 2.268 data dibandingkan kelas asma yang hanya berjumlah 124 data. Ketidakseimbangan kelas yang ekstrem ini, dengan rasio sekitar 18:1, berpotensi menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan pola pada kelas minoritas, sehingga dapat memengaruhi kualitas klasifikasi secara keseluruhan.

Sebelum dilakukan penyeimbangan data menggunakan SMOTE, dataset terlebih dahulu dibagi menjadi data training dan data testing menggunakan metode train-test split dengan perbandingan 80:20. Pembagian data ini bertujuan untuk menyediakan data yang digunakan dalam proses pelatihan model serta data yang digunakan untuk mengevaluasi performa model pada data yang belum pernah dilihat sebelumnya. Dari total 2.392 data, sebanyak 80% digunakan sebagai data training dan 20% digunakan sebagai data testing.

Tabel 4.1 Distribusi Kelas pada Pembagian Dataset

Subset	Non-Asma	Asma	Total
Dataset Awal	2.268	124	2.392
Training Set	1.814	99	1.913
Testing Set	454	25	479

Setelah proses pembagian data dilakukan, distribusi kelas pada dataset menunjukkan kondisi yang tidak seimbang, di mana jumlah data pasien non-asma jauh lebih banyak dibandingkan jumlah data pasien asma. Ketidakseimbangan ini berpotensi menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan pola pada kelas minoritas. Untuk mengatasi permasalahan ketidakseimbangan distribusi kelas tersebut, diterapkan metode SMOTE (Synthetic Minority Over-sampling Technique) pada data pelatihan. SMOTE bekerja dengan menghasilkan sampel sintetis baru pada kelas minoritas berdasarkan interpolasi antar sampel yang berdekatan dalam ruang fitur, sehingga distribusi kelas menjadi lebih seimbang tanpa sekadar menduplikasi data yang sudah ada. Penerapan SMOTE dilakukan hanya pada data pelatihan untuk menghindari terjadinya data leakage, sedangkan data pengujian tetap menggunakan distribusi aslinya. Kondisi distribusi kelas setelah penerapan SMOTE dapat dilihat pada Gambar 4.2.



Gambar 4. 2 Jumlah Data Pada Proses SMOTETomek

Berdasarkan Gambar 4.2 terlihat bahwa setelah penerapan SMOTE, distribusi kelas pada data pelatihan menjadi seimbang antara kelas non-asma dan kelas asma, dengan masing-masing kelas memiliki jumlah data yang proporsional. Dengan kondisi data yang seimbang ini, model MLP diharapkan dapat mempelajari pola dari kedua kelas secara lebih merata, sehingga kemampuan deteksi kasus asma sebagai kelas minoritas dapat meningkat secara signifikan.

4.2 Skenario Uji Coba

Skenario pertama yang diuji dalam penelitian ini adalah kedalaman dan konfigurasi hidden layer pada model MLP. Hidden layer berperan sebagai komponen utama dalam memodelkan hubungan non-linear antar fitur input, sehingga jumlah layer dan jumlah neuron yang digunakan dapat memengaruhi kapasitas pembelajaran model.

Pada penelitian ini digunakan dua variasi arsitektur, yaitu model dengan 2 hidden layer dan model dengan 3 hidden layer. Model dengan 2 hidden layer digunakan untuk merepresentasikan arsitektur yang lebih sederhana dengan kompleksitas moderat, sedangkan model dengan 3 hidden layer digunakan untuk merepresentasikan arsitektur yang lebih dalam dan memiliki kapasitas representasi yang lebih tinggi.

Berdasarkan dua variabel utama tersebut, yaitu variasi arsitektur hidden layer dan kondisi distribusi data, disusun kombinasi skenario pengujian yang mengintegrasikan seluruh kemungkinan konfigurasi yang telah ditentukan. Setiap konfigurasi arsitektur diuji pada kedua kondisi dataset, sehingga diperoleh total delapan skenario eksperimen.

Seluruh kombinasi pengujian tersebut dirangkum dalam Tabel 4.1 yang memuat rincian arsitektur jaringan dan kondisi dataset yang digunakan pada masing-masing percobaan. Dengan pendekatan ini, penelitian dapat membandingkan secara langsung pengaruh kompleksitas arsitektur dan strategi penanganan ketidakseimbangan data terhadap performa model dalam mendeteksi asma.

Tabel 4.1 Kombinasi Pengujian MLP

Uji Coba	Hidden Layer	Dataset	Jumlah Neuron
1	2	Imbalance	20-32-16-1
2			20-64-32-1
3	3		20-32-16-8-1
4			20-64-32-16-1
5	2	Balance Data menggunakan Smote	20-32-16-1
6			20-64-32-1
7	3		20-32-16-8-1
8			20-64-32-16-1

Pada proses pelatihan, model dilatih dengan maksimum 500 epoch menggunakan optimizer Adam dengan learning rate sebesar 0,001 dan batch size sebesar 32. Evaluasi performa model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score dengan metode 5-fold cross-validation.

Selama proses pelatihan, bobot dan bias jaringan diperbarui secara iteratif menggunakan mekanisme *backpropagation* berdasarkan nilai *Binary Cross-Entropy Loss*, yang sesuai untuk tugas klasifikasi biner. Pada setiap iterasi, model menghasilkan probabilitas kelas yang kemudian digunakan untuk memperbarui parameter hingga seluruh *epoch* terpenuhi.

Setelah proses pelatihan selesai, model diuji menggunakan data uji yang telah dipisahkan sebelumnya dari data pelatihan. Pada tahap ini, parameter bobot dan bias hasil pelatihan digunakan tanpa dilakukan proses pembaruan ulang. Data uji diproses melalui arsitektur Multilayer Perceptron (MLP) yang telah dilatih untuk menghasilkan prediksi kelas asma atau non-asma.

Hasil prediksi pada data uji kemudian dibandingkan dengan label aktual untuk menilai performa model. Evaluasi dilakukan menggunakan *confusion matrix* sebagai dasar perhitungan metrik evaluasi.

1. Accuracy

Accuracy menunjukkan proporsi prediksi yang benar terhadap keseluruhan data uji. Nilai accuracy dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Precision

Precision menunjukkan seberapa banyak prediksi positif (asma) yang benar-benar sesuai dengan kondisi sebenarnya. Precision dihitung dengan persamaan:

$$Precision = \frac{TP}{TP + FP}$$

3. Recall (Sensitivitas)

Recall atau sensitivitas menunjukkan kemampuan model dalam mendeteksi seluruh kasus asma yang sebenarnya. Persamaan recall adalah:

$$Recall = \frac{TP}{TP + FN}$$

4. F1-Score

F1-Score merupakan rata-rata harmonis antara precision dan recall yang memberikan gambaran keseimbangan performa model. Persamaan F1-Score adalah:

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

Struktur *confusion matrix* yang digunakan dalam penelitian ini ditunjukkan pada Tabel 3.3, yang memetakan hasil klasifikasi ke dalam empat komponen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN).

Mengingat dataset memiliki distribusi kelas yang tidak seimbang, di mana jumlah pasien asma lebih sedikit dibandingkan non-asma, maka metrik F1-Score

menjadi perhatian utama dalam mengevaluasi kemampuan model dalam mendeteksi kelas minoritas.

Struktur dari confusion matrix yang digunakan dalam penelitian ini dapat dilihat pada Tabel 4.2

Tabel 4.2 Hasil Klasifikasi Berdasarkan Kelas Negatif dan Positif

<i>Actual Class</i>		<i>Assigned Class</i>	
		<i>Positif</i>	<i>Negatif</i>
	<i>Positif</i>	TP	FN
	<i>Negatif</i>	FP	TN

Keterangan :

- True Positive (TP): Jumlah data yang sebenarnya termasuk dalam kelas asma (label 1) dan berhasil diprediksi dengan benar sebagai asma oleh model.
- True Negative (TN): Jumlah data yang sebenarnya termasuk dalam kelas non-asma (label 0) dan berhasil diprediksi dengan benar sebagai non-asma oleh model.
- False Positive (FP): Jumlah data yang sebenarnya termasuk dalam kelas non-asma (label 0), namun diprediksi sebagai asma (label 1) oleh model.
- False Negative (FN): Jumlah data yang sebenarnya termasuk dalam kelas asma (label 1), tetapi diprediksi sebagai non-asma (label 0) oleh model. Dalam konteks medis, kesalahan ini menjadi perhatian penting karena kasus asma yang sebenarnya terjadi tidak berhasil terdeteksi oleh sistem.

Confusion matrix dibangun menggunakan data pengujian setelah model dilatih dan menjadi dasar perhitungan metrik evaluasi seperti akurasi, presisi, sensitivitas, dan F1-Score.


4.2.1 Hasil Uji Coba Skenario 1

Berikut ini disajikan hasil pengujian model MLP pada Skenario 1 yang menggunakan arsitektur dua hidden layer dengan konfigurasi neuron 20-32-16-1 dan threshold 0.5 pada kondisi data imbalanced. Evaluasi dilakukan menggunakan 5-fold cross-validation dengan metrik Accuracy, Precision, Recall, dan F1-Score.

Tabel 4.3 hasil Uji Coba Skenario 1


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	98,2%	100,0%	65,0%	78,8%
2	97,9%	83,3%	75,0%	78,9%
3	97,4%	77,8%	70,0%	73,7%
4	98,2%	92,9%	68,4%	78,8%
5	97,9%	80,0%	80,0%	80,0%
Rata-rata	97,91%	86,79%	71,68%	78,04%

Tabel 4.3 di atas menyajikan hasil evaluasi model MLP Skenario 1 menggunakan arsitektur dua hidden layer dengan konfigurasi neuron 20-32-16-1 pada kondisi data imbalanced dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 97,91%, Precision sebesar 86,79%, Recall sebesar 71,68%, dan F1-Score sebesar 78,04%. Nilai Accuracy yang tinggi mencerminkan kemampuan model dalam mengklasifikasikan keseluruhan data dengan baik. Namun, nilai Recall yang relatif lebih rendah dibandingkan Precision mengindikasikan bahwa model masih melewatkan sejumlah kasus asma (False Negative), yakni pasien asma yang salah diklasifikasikan sebagai non-asma. Hal ini merupakan konsekuensi umum dari kondisi data imbalanced, di mana dominasi kelas negatif mendorong model untuk lebih berhati-hati dalam memprediksi kelas positif.




Gambar 4.3 visualisasi Confusion Matrix Model 1

Confusion matrix pada Gambar 4.3 memvisualisasikan distribusi prediksi model pada seluruh fold. Terlihat bahwa sebagian besar sampel kelas negatif (non-asma) berhasil diklasifikasikan dengan benar, sedangkan terdapat beberapa sampel kelas positif (asma) yang masih salah diklasifikasikan sebagai negatif. Ketidakseimbangan distribusi kelas pada data imbalanced menyebabkan model cenderung lebih banyak memprediksi kelas negatif, sehingga memengaruhi nilai Precision yang dihasilkan.



Gambar 4.4 Grafik *Training Loss* Model MLP Skenario 1

Grafik Training Loss pada Gambar 4.4 menunjukkan penurunan nilai loss secara konsisten seiring bertambahnya epoch pelatihan. Kurva loss pada data latih dan data validasi menunjukkan pola konvergensi yang relatif stabil tanpa terjadi lonjakan signifikan, mengindikasikan bahwa proses optimasi berjalan dengan baik pada konfigurasi arsitektur ini.



Gambar 4.5 Grafik *Training Accuracy* Model MLP Skenario 1

Grafik Training Accuracy pada Gambar 4.5 memperlihatkan peningkatan akurasi model selama proses pelatihan. Kurva akurasi data latih dan validasi cenderung meningkat dan stabil pada nilai yang tinggi, mengonfirmasi bahwa model berhasil mempelajari pola dari data pelatihan. Namun, tingginya akurasi keseluruhan perlu dilihat secara kritis mengingat kondisi data yang tidak seimbang, di mana model bisa saja lebih banyak memprediksi kelas mayoritas.


4.2.2 Hasil Uji Coba Skenario 2

Berikut ini disajikan hasil pengujian model MLP pada Skenario 2 yang menggunakan arsitektur dua hidden layer dengan konfigurasi neuron yang lebih lebar, yaitu 20-64-32-1 dengan threshold 0.5 pada kondisi data imbalanced. Peningkatan jumlah neuron ini bertujuan untuk menguji apakah kapasitas representasi yang lebih besar dapat meningkatkan performa deteksi asma.

Tabel 4.4 Hasil Uji Coba Skenario 2


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,7%	86,7%	65,0%	74,3%
2	98,2%	93,3%	70,0%	80,0%
3	97,7%	78,9%	75,0%	76,9%
4	98,2%	87,5%	73,7%	80,0%
5	98,4%	81,8%	90,0%	85,7%
Rata-rata	98,01%	85,65%	74,74%	79,38%

Tabel 4.4 di atas menyajikan hasil evaluasi model MLP Skenario 2 menggunakan arsitektur dua hidden layer dengan konfigurasi neuron 20-64-32-1 pada kondisi data imbalanced dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 98,01%, Precision sebesar 85,65%, Recall sebesar 74,74%, dan F1-Score sebesar 79,38%. Dibandingkan Skenario 1, peningkatan jumlah neuron pada setiap layer terbukti meningkatkan performa secara keseluruhan, terutama pada nilai Recall yang meningkat dari 71,68% menjadi 74,74%. Nilai Precision yang tetap tinggi menunjukkan berkurangnya prediksi positif palsu, sementara Recall yang meningkat mengindikasikan model semakin mampu mendeteksi kasus asma.




Gambar 4.6 Visualisasi *Confusion Matrix* Model 2

Confusion matrix pada Gambar 4.6 memperlihatkan distribusi prediksi model Skenario 2. Dibandingkan Skenario 1, jumlah False Positive berkurang, yang konsisten dengan peningkatan nilai Precision. Model dengan kapasitas neuron yang lebih besar mampu mempelajari batas keputusan yang lebih baik antara kelas asma dan non-asma, meskipun ketidakseimbangan data masih memengaruhi performa secara keseluruhan.



Gambar 4.7 Grafik *Training Loss* Model MLP Skenario 2

Grafik Training Loss pada Gambar 4.7 menunjukkan penurunan loss yang lebih smooth dibandingkan Skenario 1, mencerminkan bahwa kapasitas neuron yang lebih besar membantu model dalam mengoptimalkan parameter secara lebih efektif. Konvergensi antara kurva loss data latih dan validasi berlangsung stabil, mengindikasikan tidak adanya gejala overfitting yang signifikan pada konfigurasi ini.



Gambar 4.8 Grafik *Training Accuracy* Model MLP Skenario 2

Grafik Training Accuracy pada Gambar 4.8 memperlihatkan peningkatan akurasi yang lebih cepat dan konsisten dibandingkan Skenario 1. Kurva akurasi data latih dan validasi menunjukkan tren yang selaras, mengonfirmasi bahwa model dengan arsitektur neuron yang lebih lebar mampu belajar lebih efisien dari data pelatihan sekaligus mempertahankan kemampuan generalisasinya.


4.2.3 Hasil Uji Coba Skenario 3

Berikut ini disajikan hasil pengujian model MLP pada Skenario 3 yang menambahkan satu hidden layer sehingga arsitektur menjadi tiga hidden layer dengan konfigurasi neuron 20-32-16-8-1 dan threshold 0.5 pada kondisi data imbalanced. Penambahan kedalaman jaringan ini bertujuan untuk menguji apakah model yang lebih dalam mampu menangkap pola non-linear yang lebih kompleks dari data rekam medis asma.

Tabel 4.5 Hasil Uji Coba Skenario 3


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,9%	92,9%	65,0%	76,5%
2	97,7%	78,9%	75,0%	76,9%
3	97,4%	77,8%	70,0%	73,7%
4	97,9%	86,7%	68,4%	76,5%
5	96%	81,0%	85,0%	82,9%
Rata-rata	98,2%	83,44%	72,68%	77,30%

Tabel 4.5 di atas menyajikan hasil evaluasi model MLP Skenario 3 yang menambah satu hidden layer dengan konfigurasi neuron 20-32-16-8-1 pada kondisi data imbalanced dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 97,80%, Precision sebesar 83,44%, Recall sebesar 72,68%, dan F1-Score sebesar 77,30%. Meskipun arsitektur lebih dalam, performa justru menurun dibandingkan Skenario 2, terutama pada nilai Precision dan F1-Score. Hal ini mengindikasikan bahwa penambahan kedalaman jaringan tanpa disertai kapasitas neuron yang memadai belum tentu meningkatkan performa, khususnya pada kondisi data imbalanced.




Gambar 4.9 Visualisasi *Confusion Matrix* Model 3

Confusion matrix pada Gambar 4.9 menunjukkan bahwa model Skenario 3 menghasilkan lebih banyak False Positive dibandingkan Skenario 2. Kondisi ini mencerminkan bahwa arsitektur yang lebih dalam dengan jumlah neuron terbatas menyebabkan model kurang optimal dalam membedakan antara kelas asma dan non-asma, sehingga lebih sering salah mengklasifikasikan sampel negatif sebagai positif.



Gambar 4.10 Grafik *Training Loss* Model MLP Skenario 3

Grafik Training Loss pada Gambar 4.10 memperlihatkan proses pelatihan yang kurang stabil dibandingkan skenario sebelumnya. Terdapat fluktuasi pada kurva loss validasi di beberapa fold, mengindikasikan bahwa arsitektur tiga hidden layer dengan kapasitas neuron yang terbatas pada data imbalanced menyulitkan proses optimasi untuk mencapai konvergensi yang konsisten.



Gambar 4.11 Grafik *Training Accuracy* Model MLP Skenario 3

Grafik Training Accuracy pada Gambar 4.11 memperlihatkan akurasi keseluruhan yang masih tinggi, namun terdapat variasi antar fold yang lebih besar dibandingkan Skenario 1 dan 2. Tingginya akurasi tetap banyak disumbang oleh prediksi kelas negatif yang dominan pada data imbalanced, sedangkan kemampuan model dalam mendeteksi kelas asma sebagai kelas minoritas menjadi relatif lebih rendah.


4.2.4 Hasil Uji Coba Skenario 4

Berikut ini disajikan hasil pengujian model MLP pada Skenario 4 yang menggunakan arsitektur tiga hidden layer dengan konfigurasi neuron paling lebar pada kondisi imbalanced, yaitu 20-64-32-16-1 dan threshold 0.5. Skenario ini merupakan pengujian terakhir pada kondisi data imbalanced yang menggabungkan kedalaman dan kapasitas neuron yang lebih besar.

Tabel 4.6 Hasil Uji Coba Skenario 4


<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,7%	86,7%	65,0%	74,3%
2	98,4%	93,8%	75,0%	83,3%
3	97,4%	77,8%	70,0%	73,7%
4	98,4%	93,3%	73,7%	82,4%
5	98,4%	81,8%	90,0%	85,7%
Rata-rata	98,07%	86,67%	74,74%	79,87%

Tabel 4.6 di atas menyajikan hasil evaluasi model MLP Skenario 4 menggunakan arsitektur tiga hidden layer dengan konfigurasi neuron paling lebar pada kondisi imbalanced, yaitu 20-64-32-16-1 dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 98,07%, Precision sebesar 86,67%, Recall sebesar 74,74%, dan F1-Score sebesar 79,87%, yang merupakan performa terbaik di antara seluruh skenario data imbalanced. Peningkatan jumlah neuron pada setiap layer terbukti meningkatkan kapasitas model dalam mempelajari hubungan antar fitur klinis yang kompleks, sehingga menghasilkan keseimbangan yang lebih baik antara Precision dan Recall.




Gambar 4.12 Visualisasi *Confusion Matrix* Model 4

Confusion matrix pada Gambar 4.12 memvisualisasikan distribusi prediksi model Skenario 4 yang merupakan skenario terbaik pada kondisi data imbalanced. Dibandingkan skenario imbalanced sebelumnya, terlihat penurunan jumlah False Positive dan False Negative secara bersamaan, mencerminkan kemampuan model dalam mengklasifikasikan kedua kelas dengan lebih seimbang. Model dengan arsitektur yang lebih lebar mampu menangkap representasi fitur yang lebih kaya dari data rekam medis asma.



Gambar 4.13 Grafik *Training Loss* Model MLP Skenario 4

Grafik Training Loss pada Gambar 4.13 menunjukkan pola konvergensi yang paling stabil di antara seluruh skenario imbalanced. Penurunan loss berlangsung secara konsisten pada setiap fold, dan jarak antara kurva training loss dengan validation loss yang relatif kecil mengindikasikan bahwa model mampu melakukan generalisasi yang baik tanpa mengalami overfitting yang signifikan.



Gambar 4.14 Grafik *Training Accuracy* Model MLP Skenario 4

Grafik Training Accuracy pada Gambar 4.14 memperlihatkan peningkatan akurasi yang cepat dan stabil sepanjang proses pelatihan. Konsistensi kurva akurasi antar fold mencerminkan bahwa arsitektur 20-64-32-16-1 dengan data imbalanced mampu menghasilkan model yang stabil. Nilai akurasi validasi yang tinggi dan konsisten mengonfirmasi bahwa Skenario 4 merupakan konfigurasi terbaik pada kondisi data tanpa penyeimbangan.

4.3 Hasil Uji Coba Data *Balanced*

Pada tahap ini dilakukan pengujian model Multilayer Perceptron (MLP) menggunakan data balanced hasil penerapan Synthetic Minority Oversampling Technique (SMOTE). Penerapan SMOTE bertujuan untuk mengatasi ketidakseimbangan distribusi kelas pada dataset asma dengan menghasilkan sampel sintetis pada kelas minoritas, sehingga proses pembelajaran model dapat berlangsung lebih seimbang. Pengujian pada kondisi data balanced dilakukan untuk

mengevaluasi apakah distribusi data yang lebih proporsional mampu meningkatkan kemampuan model dalam mendeteksi pasien asma dibandingkan kondisi data imbalanced.

Skenario pengujian pada data balanced menggunakan konfigurasi arsitektur yang sama seperti pengujian sebelumnya, yaitu variasi dua hidden layer dan tiga hidden layer dengan jumlah neuron yang berbeda. Setiap arsitektur diuji menggunakan K-Fold Cross Validation sehingga performa model dapat dianalisis secara lebih menyeluruh berdasarkan metrik Accuracy, Precision, Recall, dan F1-Score.

Secara umum, hasil pengujian pada data balanced menunjukkan peningkatan nilai Precision dan F1-Score dibandingkan pengujian pada data imbalanced. Hal ini mengindikasikan bahwa distribusi data yang lebih seimbang membantu model dalam mengurangi kesalahan klasifikasi terhadap kelas mayoritas maupun kelas minoritas. Selain itu, proses pelatihan model juga menunjukkan pola konvergensi yang lebih stabil karena model memperoleh representasi data yang lebih proporsional pada setiap fold pengujian.


4.3.1 Hasil Uji Coba Skenario 5

Berikut ini disajikan hasil pengujian model MLP pada Skenario 5 yang merupakan pengujian pertama menggunakan data balanced hasil augmentasi SMOTE. Model menggunakan arsitektur dua hidden layer dengan konfigurasi neuron 20-32-16-1 dan threshold 0.5, identik dengan Skenario 1 namun pada kondisi data yang telah diseimbangkan.


Tabel 4.7 Hasil Uji Coba Skenario 5

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,4%	81,2%	65,0%	72,2%
2	98,2%	88,2%	75,0%	81,1%
3	97,7%	82,4%	70,0%	75,7%
4	97,9%	86,7%	68,4%	76,5%
5	98,2%	84,2%	80,0%	82,1%
Rata-rata	97,86%	84,54%	71,68%	77,50%

Tabel 4.7 di atas menyajikan hasil evaluasi model MLP Skenario 5 sebagai pengujian pertama menggunakan data balanced (SMOTE) dengan arsitektur dua hidden layer 20-32-16-1 dan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 97,86%, Precision sebesar 84,54%, Recall sebesar 71,68%, dan F1-Score sebesar 77,50%. Dibandingkan Skenario 1 dengan arsitektur setara namun data imbalanced, nilai Precision dan F1-Score pada Skenario 5 menunjukkan performa yang sebanding, dengan keseimbangan kelas yang lebih baik berkat penerapan SMOTETomek. Namun, nilai Recall yang sama dengan Skenario 1 menunjukkan bahwa pada arsitektur dengan kapasitas representasi moderat, pengaruh penyeimbangan data terhadap kemampuan deteksi kelas positif masih terbatas.


Gambar 4.15 Visualisasi *Confusion Matrix* Model 5

Confusion matrix pada Gambar 4.15 memperlihatkan dampak positif penerapan SMOTE terhadap performa model. Jumlah False Positive yang dihasilkan jauh lebih sedikit dibandingkan skenario imbalanced, konsisten dengan peningkatan nilai Precision yang signifikan. Namun, terdapat peningkatan False Negative, menunjukkan bahwa sebagian kasus asma masih terlewatkan oleh model pada konfigurasi dengan kapasitas neuron yang lebih terbatas.



Gambar 4.16 Grafik *Training Loss* Model MLP Skenario 5

Grafik Training Loss pada Gambar 4.16 menunjukkan bahwa penerapan SMOTE memberikan distribusi data yang lebih seimbang sehingga proses optimasi berjalan lebih terarah. Kurva loss baik pada data latih maupun validasi menunjukkan penurunan yang lebih konsisten dibandingkan skenario imbalanced setara, mengindikasikan bahwa keseimbangan kelas membantu proses pembelajaran model secara keseluruhan.



Gambar 4.17 Grafik *Training Accuracy* Model MLP Skenario 5

Grafik Training Accuracy pada Gambar 4.17 memperlihatkan akurasi yang lebih tinggi dan stabil dibandingkan Skenario 1. Dengan data yang telah diseimbangkan menggunakan SMOTE, model mampu belajar dari representasi kedua kelas secara lebih proporsional, sehingga peningkatan akurasi lebih mencerminkan kemampuan klasifikasi yang sesungguhnya, bukan semata-mata dominasi kelas mayoritas.


4.3.2 Hasil Uji Coba Skenario 6

Berikut ini disajikan hasil pengujian model MLP pada Skenario 6 yang menggunakan arsitektur dua hidden layer dengan konfigurasi neuron lebih lebar, yaitu 20-64-32-1 dan threshold 0.5 pada kondisi data balanced (SMOTE). Skenario ini bertujuan menguji apakah peningkatan kapasitas neuron pada data yang sudah diseimbangkan dapat lebih jauh meningkatkan performa deteksi asma.


Tabel 4.8 Hasil Uji Coba Skenario 6

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,4%	77,8%	70.0%	73,7%
2	97,7%	76,2%	80.0%	78,0%
3	98,2%	81,0%	85.0%	82,9%
4	98,4%	93,3%	73,7%	82,4%
5	98,4%	88,9%	80,0%	84,2%
Rata-rata	98,01%	83,43%	77,74%	80,24%

Tabel 4.8 di atas menampilkan hasil evaluasi model MLP Skenario 6 menggunakan arsitektur dua hidden layer 20-64-32-1 pada kondisi data balanced dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 98,01%, Precision sebesar 83,43%, Recall sebesar 77,74%, dan F1-Score sebesar 80,24%. Dibandingkan Skenario 5, arsitektur dengan kapasitas neuron yang lebih besar pada data balanced menghasilkan peningkatan yang lebih seimbang antara Precision dan Recall, yang tercermin dari nilai F1-Score yang lebih tinggi. Keseimbangan ini mengindikasikan bahwa perluasan kapasitas neuron mampu meningkatkan kemampuan deteksi asma secara menyeluruh.


Gambar 4.18 Visualisasi *Confusion Matrix* Model 6

Confusion matrix pada Gambar 4.18 memperlihatkan keseimbangan yang lebih baik antara True Positive dan True Negative dibandingkan Skenario 5. Penurunan jumlah False Negative mengindikasikan bahwa model dengan neuron yang lebih banyak mampu mendeteksi lebih banyak kasus asma yang sesungguhnya, sementara jumlah False Positive juga tetap terkendali berkat pengaruh SMOTE dalam menyeimbangkan distribusi kelas.



Gambar 4. 19 Grafik Training Loss Model MLP Skenario 6

Grafik Training Loss pada Gambar 4.19 menunjukkan pola konvergensi yang smooth dan konsisten antar fold. Kurva loss pada data latih dan validasi menunjukkan penurunan yang selaras tanpa gap yang besar, mengindikasikan tidak adanya overfitting yang berarti. Kombinasi antara data balanced dan kapasitas neuron yang lebih besar tampak memberikan kondisi pelatihan yang lebih optimal.



Gambar 4.20 Grafik *Training Accuracy* Model MLP Skenario 6

Grafik Training Accuracy pada Gambar 4.20 memperlihatkan peningkatan akurasi yang paling konsisten di antara seluruh skenario dengan dua hidden layer. Kurva akurasi validasi yang mendekati kurva akurasi latih pada hampir semua fold mengonfirmasi kemampuan generalisasi model yang baik. Nilai F1-Score 82% yang tertinggi di antara skenario data balanced dengan dua hidden layer menjadi bukti efektivitas konfigurasi ini.


4.3.3 Hasil Uji Coba Skenario 7

Berikut ini disajikan hasil pengujian model MLP pada Skenario 7 yang menguji arsitektur tiga hidden layer dengan konfigurasi neuron 20-32-16-8-1 dan threshold 0.5 pada kondisi data balanced (SMOTE). Skenario ini bertujuan untuk mengevaluasi apakah kedalaman jaringan yang lebih besar dengan data yang seimbang dapat meningkatkan performa deteksi asma.


Tabel 4.9 Hasil Uji Coba Skenario 7

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	98,2%	93,3%	70,0%	80,0%
2	97,9%	83,3%	75,0%	78,9%
3	97,4%	75,0%	75,0%	75,0%
4	97,4%	80,0%	63,2%	70,6%
5	97,9%	83,3%	75,0%	78,9%
Rata-rata	97,75%	83,00%	71,63%	76,70%

Tabel 4.9 di atas menyajikan hasil evaluasi model MLP Skenario 7 yang menguji arsitektur tiga hidden layer 20-32-16-8-1 pada kondisi data balanced dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 97,75%, Precision sebesar 83,00%, Recall sebesar 71,63%, dan F1-Score sebesar 76,70%. Dibandingkan Skenario 5 dengan arsitektur dua hidden layer pada data balanced, nilai F1-Score yang dihasilkan lebih rendah, mengindikasikan bahwa penambahan kedalaman jaringan dengan kapasitas neuron yang terbatas belum memberikan manfaat optimal pada data yang telah diseimbangkan.


Gambar 4.21 Visualisasi *Confusion Matrix* Model 7

Confusion matrix pada Gambar 4.21 menunjukkan distribusi prediksi yang cukup baik, namun terdapat peningkatan False Negative dibandingkan Skenario 6. Model dengan tiga hidden layer tetapi kapasitas neuron yang lebih kecil pada layer terdalam tampak kurang efektif dalam menangkap pola kelas asma secara menyeluruh, meskipun data sudah diseimbangkan menggunakan SMOTE.



Gambar 4.22 Grafik Training Loss Model MLP Skenario 7

Grafik Training Loss pada Gambar 4.22 memperlihatkan variasi yang lebih besar antar fold dibandingkan skenario dua hidden layer. Fluktuasi pada kurva validation loss mengindikasikan bahwa arsitektur tiga hidden layer dengan kapasitas neuron terbatas mengalami kesulitan untuk mencapai konvergensi yang konsisten pada setiap partisi data, yang pada akhirnya memengaruhi stabilitas performa model.



Gambar 4.23 Grafik Training Accuracy Model MLP Skenario 7

Grafik Training Accuracy pada Gambar 4.23 menunjukkan variasi performa antar fold yang lebih besar dibandingkan skenario dengan dua hidden layer. Meskipun nilai akurasi keseluruhan masih relatif tinggi, ketidakstabilan ini mencerminkan bahwa penambahan kedalaman jaringan tanpa perluasan kapasitas neuron yang memadai dapat menyebabkan proses pelatihan yang kurang konsisten pada setiap fold.


4.3.4 Hasil Uji Coba Skenario 8

Berikut ini disajikan hasil pengujian model MLP pada Skenario 8 yang merupakan pengujian terakhir menggunakan arsitektur tiga hidden layer dengan konfigurasi neuron paling lebar pada kondisi data balanced, yaitu 20-64-32-16-1 dan threshold 0.5. Skenario ini menggabungkan kedalaman jaringan maksimum dengan kapasitas neuron terbesar pada data yang telah diseimbangkan menggunakan SMOTE.


Tabel 4.10 Hasil Uji Coba Skenario 8

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	97,4%	77,8%	70,0%	73,7%
2	98,2%	81,0%	85,0%	82,9%
3	98,4%	88,9%	80,0%	84,2%
4	98,4%	93,3%	73,7%	82,4%
5	98,2%	81,0%	85,0%	82,9%
Rata-rata	98,12%	84,38%	78,74%	81,22%

Tabel 4.10 di atas menyajikan hasil evaluasi model MLP Skenario 8 sebagai pengujian terakhir menggunakan arsitektur tiga hidden layer dengan konfigurasi neuron paling lebar pada kondisi data balanced, yaitu 20-64-32-16-1 dengan threshold 0.5. Model menghasilkan rata-rata Accuracy sebesar 98,12%, Precision sebesar 84,38%, Recall sebesar 78,74%, dan F1-Score sebesar 81,22%. Hasil ini merupakan salah satu performa terbaik pada kondisi data balanced, dengan keseimbangan yang baik antara Precision dan Recall. Dibandingkan Skenario 7, peningkatan jumlah neuron pada setiap layer terbukti meningkatkan kemampuan model dalam mendeteksi kasus asma secara lebih akurat.


Gambar 4.24 Visualisasi *Confusion Matrix* Model 8

Confusion matrix pada Gambar 4.24 memvisualisasikan distribusi prediksi model Skenario 8. Terlihat bahwa model mampu mengklasifikasikan sebagian besar sampel kedua kelas dengan tepat, dengan jumlah True Positive yang lebih banyak dibandingkan Skenario 7. Kombinasi antara arsitektur tiga hidden layer yang lebih lebar dan data balanced menghasilkan model yang mampu membedakan antara pasien asma dan non-asma dengan lebih konsisten.



Gambar 4.25 Grafik *Training Loss* Model MLP Skenario 8

Grafik Training Loss pada Gambar 4.25 menunjukkan pola konvergensi yang lebih stabil dibandingkan Skenario 7, seiring dengan peningkatan kapasitas neuron pada setiap layer. Kurva loss data latih dan validasi menurun secara konsisten dan relatif beriringan, mengindikasikan proses generalisasi model yang baik. Stabilitas ini mencerminkan bahwa kombinasi data balanced dengan arsitektur yang lebih besar menghasilkan proses pelatihan yang lebih efektif.



Gambar 4.26 Grafik *Training Accuracy* Model MLP Skenario 8

Grafik Training Accuracy pada Gambar 4.26 memperlihatkan performa model yang relatif konsisten dan stabil antar fold. Kurva akurasi validasi yang tinggi dan beriringan dengan kurva akurasi latih mengonfirmasi kemampuan generalisasi model. Hasil pelatihan yang stabil ini mendukung Skenario 8 sebagai salah satu konfigurasi terbaik dalam penelitian ini, menggabungkan kedalaman jaringan dengan kapasitas neuron yang memadai pada data yang telah diseimbangkan.

4.4 Pembahasan

Penelitian ini bertujuan untuk menganalisis performa model Multilayer Perceptron (MLP) dalam mendeteksi indikasi penyakit asma berdasarkan data rekam medis pasien menggunakan metrik Accuracy, Precision, Recall, dan F1-Score. Selain itu, penelitian juga bertujuan mengkaji pengaruh variasi arsitektur

hidden layer, jumlah neuron, serta penerapan penyeimbangan data menggunakan SMOTE terhadap kemampuan model dalam melakukan klasifikasi secara optimal. Evaluasi dilakukan menggunakan skema K-Fold Cross Validation pada kondisi data imbalanced dan balanced sehingga diperoleh gambaran performa model yang lebih komprehensif.

Tabel 4.11 Hasil Evaluasi Menggunakan Tanpa SMOTE

Skenario	Hidden Layer	Neuron	Accuracy	Precision	Recall	F1-Score
1	2	20-32-16-1	97,91%	86,79%	71,68%	78,04%
2		20-64-32-1	98,01%	85,65%	74,74%	79,38%
3	3	20-32-16-8-1	97,80%	83,44%	72,68%	77,30%
4		20-64-32-16-1	98,07%	86,67%	74,74%	79,87%

Berdasarkan Tabel 4.11, hasil evaluasi pada kondisi data imbalanced menunjukkan bahwa seluruh skenario mampu menghasilkan nilai Accuracy yang tinggi, berkisar antara 97,80% hingga 98,07%. Namun demikian, nilai Accuracy yang tinggi tersebut belum sepenuhnya mencerminkan kemampuan model yang sesungguhnya. Hal ini terbukti dari nilai Recall yang lebih rendah dibandingkan Precision, berkisar antara 71,68% hingga 74,74%, yang mengindikasikan masih adanya prediksi False Negative pada seluruh skenario imbalanced. Kondisi ini terjadi karena ketidakseimbangan kelas yang ekstrem pada data asli, di mana kelas non-asma mendominasi sebesar 94,82% dari keseluruhan data, sehingga model cenderung memprediksi kelas mayoritas dan mengabaikan pola pada kelas minoritas. Di sisi lain, nilai Precision yang tinggi antara 83,44% hingga 86,79% menunjukkan bahwa model cukup baik dalam menghindari prediksi positif palsu, meskipun kemampuan deteksi kelas asma secara keseluruhan masih perlu ditingkatkan.

Sementara itu, penerapan SMOTETomek pada kondisi data balanced memberikan perubahan yang signifikan terhadap pola performa model, sebagaimana ditunjukkan pada Tabel 4.12. Seluruh skenario dengan SMOTETomek menghasilkan peningkatan Recall yang substansial, yaitu berkisar antara 71,63% hingga 78,74%, dengan Accuracy yang tetap terjaga pada nilai 97,75% hingga 98,12%. Keseimbangan distribusi kelas yang dihasilkan oleh SMOTETomek memungkinkan model untuk mempelajari pola dari kedua kelas secara lebih merata, sehingga batas keputusan antar kelas dapat dipelajari dengan lebih baik. Hal ini tercermin dari nilai F1-Score yang lebih tinggi dan lebih seimbang dibandingkan kondisi imbalanced.

Tabel 4.12 Hasil Evaluasi Menggunakan SMOTE

Skenario	Hidden Layer	Neuron	Accuracy	Precision	Recall	F1-Score
5	2	20-32-16-1	97,86%	84,54%	71,68%	77,50%
6		20-64-32-1	98,01%	83,43%	77,74%	80,24%
7	3	20-32-16-8-1	97,75%	83,00%	71,63%	76,70%
8		20-64-32-16-1	98,12%	84,38%	78,74%	81,22%

Secara keseluruhan, penerapan SMOTE terbukti menghasilkan nilai F1-Score yang lebih tinggi dan lebih seimbang dibandingkan kondisi tanpa SMOTE, sehingga lebih merepresentasikan performa model secara komprehensif.

Berdasarkan perbandingan seluruh skenario, konfigurasi dua hidden layer dengan arsitektur neuron 20-64-32-1 pada kondisi data balanced (Skenario 6) menghasilkan keseimbangan performa terbaik secara keseluruhan, dengan Accuracy 98,01%, Precision 83,43%, Recall 77,74%, dan F1-Score 80,24%. Hasil ini menegaskan bahwa kombinasi antara kapasitas neuron yang memadai dan penyeimbangan data menggunakan SMOTETomek merupakan pendekatan yang

paling efektif dalam membangun model MLP untuk deteksi indikasi asma. Temuan ini selaras dengan pentingnya penggunaan F1-Score sebagai metrik evaluasi utama pada permasalahan dengan distribusi kelas yang tidak seimbang, karena metrik tersebut mempertimbangkan keseimbangan antara Precision dan Recall secara bersamaan dibandingkan hanya mengandalkan nilai Accuracy semata.

4.4.1 Pengaruh Arsitektur MLP (Hidden Layer dan Neuron)

Berdasarkan hasil pengujian pada seluruh skenario, konfigurasi arsitektur Multilayer Perceptron (MLP) menunjukkan pengaruh yang cukup signifikan terhadap performa klasifikasi deteksi asma. Evaluasi dilakukan dengan membandingkan jumlah hidden layer dan jumlah neuron pada setiap arsitektur menggunakan metrik Precision, Recall, dan F1-Score. Rangkuman hasil pengujian ditunjukkan pada Tabel 4.12.

Tabel 4.13 Perbandingan *Hidden Layer 2*

Skenario	20-32-16-1			
	Accuracy	Precision	Recall	F1 Score
1	97,91%	86,79%	71,68%	78,04%
5	97,86%	84,54%	71,68%	77,50%
Rata-rata	97,89%	85,67%	71,68%	77,77%
Skenario	20-64-32-1			
	Accuracy	Precision	Recall	F1 Score
2	98,01%	85,65%	74,74%	79,38%
6	98,01%	83,43%	77,74%	80,24%
Rata-rata	98,01%	84,54%	76,24%	79,81%

Pada arsitektur dua hidden layer, konfigurasi 20-64-32-1 menunjukkan performa yang lebih baik dibandingkan arsitektur 20-32-16-1 terutama pada nilai Recall dan F1-Score. Arsitektur 20-64-32-1 memperoleh rata-rata Precision sebesar 84,54%, Recall sebesar 76,24%, dan F1-Score sebesar 79,81%, sedangkan arsitektur 20-32-16-1 menghasilkan rata-rata Precision sebesar 85,67%, Recall

sebesar 71,68%, dan F1-Score sebesar 77,77%. Perbedaan ini menunjukkan bahwa penambahan jumlah neuron pada hidden layer mampu meningkatkan kemampuan model dalam mempelajari pola hubungan antar fitur klinis pasien asma secara lebih optimal.

Selain itu, peningkatan kapasitas neuron juga memberikan keseimbangan performa yang lebih baik antara Precision dan Recall. Pada Skenario 2 dan 6, arsitektur 20-64-32-1 mampu mempertahankan nilai Recall yang tinggi sekaligus meningkatkan nilai Precision dibandingkan arsitektur 20-32-16-1 pada Skenario 1 dan 5. Kondisi ini mengindikasikan bahwa model dengan jumlah neuron yang lebih besar memiliki kemampuan representasi fitur yang lebih baik sehingga dapat mengurangi kesalahan klasifikasi False Positive maupun False Negative.

Tabel 4.14 Perbandingan *Hidden Layer* 3

Skenario	20-32-16-8-1			
	Accuracy	Precision	Recall	F1 Score
3	97,80%	83,44%	72,68%	77,30%
7	97,75%	83,00%	71,63%	76,70%
Rata-rata	97,78%	83,22%	72,16%	77,00%
	20-64-32-16-1			
	Accuracy	Precision	Recall	F1 Score
4	98,07%	86,67%	74,74%	79,87%
8	98,12%	84,38%	78,74%	81,22%
Rata-rata	98,10%	85,53%	76,74%	80,55%

Selanjutnya, pada arsitektur tiga hidden layer, konfigurasi 20-64-32-16-1 juga menunjukkan performa yang lebih unggul dibandingkan arsitektur 20-32-16-8-1. Arsitektur 20-64-32-16-1 memperoleh rata-rata Precision sebesar 85,53%, Recall sebesar 76,74%, dan F1-Score sebesar 80,55%, sedangkan arsitektur 20-32-16-8-1 hanya mencapai rata-rata Precision sebesar 83,22%, Recall sebesar 72,16%, dan F1-Score sebesar 77,00%. Hasil ini menunjukkan bahwa penambahan hidden

layer dapat meningkatkan performa model apabila diimbangi dengan kapasitas neuron yang memadai pada setiap layer.

Sebaliknya, arsitektur 20-32-16-8-1 mengalami penurunan performa yang cukup signifikan, khususnya pada nilai Precision dan F1-Score. Hal ini mengindikasikan bahwa penambahan kedalaman jaringan tanpa perluasan neuron yang cukup justru menyebabkan kemampuan representasi model menjadi kurang optimal. Akibatnya, model cenderung menghasilkan klasifikasi yang kurang stabil dalam membedakan pasien asma dan non-asma.

Secara keseluruhan, hasil pengujian menunjukkan bahwa peningkatan jumlah neuron memiliki pengaruh yang lebih konsisten terhadap peningkatan performa model dibandingkan hanya menambah jumlah hidden layer. Dengan demikian, kombinasi antara kedalaman jaringan dan kapasitas neuron yang seimbang menjadi faktor penting dalam menghasilkan model MLP yang optimal untuk deteksi indikasi penyakit asma.

4.4.2 Pengaruh Keseimbangan Data

Berdasarkan hasil pengujian pada kondisi data imbalanced dan balanced menggunakan SMOTE, keseimbangan distribusi data menunjukkan pengaruh yang cukup signifikan terhadap performa model Multilayer Perceptron (MLP). Analisis dilakukan dengan membandingkan nilai Precision, Recall, dan F1-Score pada setiap konfigurasi arsitektur jaringan. Rangkuman hasil pengujian disajikan pada Tabel 4.13

Tabel 4.15 Perbandingan Rata Rata Hasil *Precision Recall F1 Score* Pada Data

Skenario	Neuron	Imbalanced			
		Accuracy	Precision	Recall	F1 Score
1	20-32-16-1	97,91%	86,79%	71,68%	78,04%
2	20-64-32-1	98,01%	85,65%	74,74%	79,38%
3	20-32-16-8-1	97,80%	83,44%	72,68%	77,30%
4	20-64-32-16-1	98,07%	86,67%	74,74%	79,87%
Rata-rata		96%	97,95%	85,64%	73,46%
Skenario	Neuron	Balanced			
		Accuracy	Precision	Recall	F1 Score
5	20-32-16-1	97,86%	84,54%	71,68%	77,50%
6	20-64-32-1	98,01%	83,43%	77,74%	80,24%
7	20-32-16-8-1	97,75%	83,00%	71,63%	76,70%
8	20-64-32-16-1	98,12%	84,38%	78,74%	81,22%
Rata-rata		97%	97,94%	83,84%	74,95%

Hasil evaluasi menunjukkan bahwa penerapan SMOTETomek secara umum mampu meningkatkan nilai Recall dan F1-Score pada seluruh arsitektur yang diuji. Pada kondisi data imbalanced, model menghasilkan rata-rata Precision sebesar 85,64%, Recall sebesar 73,46%, dan F1-Score sebesar 78,65%. Setelah data diseimbangkan menggunakan SMOTETomek, rata-rata Recall meningkat menjadi 74,95% dan F1-Score meningkat menjadi 78,92%, sementara nilai Precision relatif stabil pada kisaran 83,84%.

Peningkatan nilai Recall setelah penerapan SMOTETomek menunjukkan bahwa model menjadi lebih baik dalam mendeteksi kasus asma yang sesungguhnya. Kondisi ini terjadi karena distribusi data yang lebih seimbang membuat model mampu mempelajari representasi kedua kelas secara lebih proporsional. Pada arsitektur 20-32-16-1 misalnya, nilai Recall tetap stabil pada 71,68% di kedua kondisi, sedangkan F1-Score sedikit berubah dari 78,04% pada kondisi imbalanced menjadi 77,50% pada kondisi balanced. Hasil serupa juga terlihat pada arsitektur 20-64-32-1 yang mengalami peningkatan F1-Score dari 79,38% menjadi 80,24%.

Namun demikian, peningkatan Precision tersebut diikuti dengan penurunan nilai Recall pada sebagian besar skenario. Pada kondisi data imbalanced, model

cenderung menghasilkan Recall yang sangat tinggi karena lebih agresif dalam memprediksi kelas positif asma. Setelah penerapan SMOTE, model menjadi lebih selektif dalam melakukan klasifikasi sehingga jumlah False Positive menurun, tetapi beberapa kasus positif asma tidak berhasil terdeteksi sehingga Recall ikut mengalami penurunan.

Fenomena ini menunjukkan adanya trade-off antara Precision dan Recall setelah proses penyeimbangan data dilakukan. Meskipun Recall sedikit menurun, peningkatan Precision dan F1-Score mengindikasikan bahwa model balanced memiliki performa klasifikasi yang lebih seimbang dan lebih stabil dibandingkan model pada kondisi data imbalanced.

Selain itu, hasil pengujian juga memperlihatkan bahwa pengaruh SMOTE menjadi lebih optimal pada arsitektur dengan jumlah neuron yang lebih besar. Arsitektur 20-64-32-16-1 pada kondisi balanced menghasilkan Precision sebesar 85% dan F1-Score sebesar 81%, yang merupakan performa terbaik secara keseluruhan. Hal ini menunjukkan bahwa kombinasi antara distribusi data yang seimbang dan kapasitas neuron yang besar mampu meningkatkan kemampuan model dalam mempelajari pola kompleks pada data rekam medis pasien asma.

4.5 Implementasi GUI

Pada tahap implementasi, model Multilayer Perceptron (MLP) terbaik yang telah diperoleh dari proses pengujian diintegrasikan ke dalam sebuah Graphical User Interface (GUI) berbasis web. Implementasi GUI bertujuan untuk mempermudah pengguna dalam melakukan prediksi risiko asma secara interaktif. Antarmuka sistem deteksi risiko asma terdiri dari beberapa komponen

input yang merepresentasikan fitur-fitur kesehatan pasien yang digunakan pada proses pelatihan model. Pengguna diminta mengisi data umum seperti usia, Body Mass Index (BMI), aktivitas fisik, kualitas tidur, paparan polusi, paparan serbuk, paparan debu, serta data fungsi paru-paru seperti nilai FEV1 dan FVC. Selain itu, pengguna juga dapat memilih beberapa gejala dan riwayat kondisi kesehatan yang berkaitan dengan penyakit asma, seperti wheezing, sesak napas, batuk, riwayat keluarga asma, alergi, refluks lambung (GERD), dan kebiasaan merokok.

Sistem Deteksi Risiko Asma

Isi 20 data kesehatan di bawah, lalu klik **Prediksi**.
 Model aktif: **Model 6 | 20-64-32-1 | SMOTETomek (Balanced)**
 F1 Score: 82.87% | Recall: 80.79%

DATA UMUM

Usia (tahun): 35 BMI: 22,5 Aktivitas fisik (0-10): 2

TIDUR & PAPARAN LINGKUNGAN

Kualitas tidur (0-10): 3 Paparan polusi (0-10): 10
 Paparan serbuk (0-10): 1 Paparan debu (0-10): 10

FUNGSI PARU-PARU

FEV1 (L): 2,5 FVC (L): 3,2

GEJALA YANG DIRASAKAN

☒ Wheezing (mengi) ☒ Sesak napas ☒ Dada terasa sesak ☒ Batuk


RIWAYAT & KONDISI LAIN

☐ Alergi hewan peliharaan ☒ Riwayat keluarga asma ☒ Riwayat alergi ☐ Eksim (Eczema)
☐ Demam hay (Hay fever) ☒ Refluks lambung (GERD) ☒ Merokok

Prediksi Sekarang **Reset Form**

Gambar 4.27 Tampilan Gui Input Data

menunjukkan bahwa sistem menggunakan model terbaik hasil pengujian, yaitu Model 6 dengan arsitektur 20-64-32-1 pada kondisi balanced menggunakan SMOTETomek. Model tersebut memiliki nilai F1-Score sebesar 82,87% dan Recall sebesar 80,79%. Informasi performa model ditampilkan pada bagian atas antarmuka untuk memberikan gambaran tingkat kemampuan model dalam melakukan klasifikasi.



Gambar 4.28 Hasil Indikasi Asma

Pada contoh implementasi, sistem menampilkan hasil prediksi berupa “Anda terindikasi ASMA” dengan probabilitas sebesar 98,8% dan kategori risiko tinggi. Selain itu, GUI juga menampilkan visualisasi persentase probabilitas dalam bentuk progress bar sehingga hasil prediksi menjadi lebih mudah dipahami oleh pengguna.

Dengan selesainya seluruh tahapan rancang bangun, pengujian, dan analisis terhadap sistem deteksi indikasi penyakit asma menggunakan metode *Multilayer Perceptron* (MLP) ini, penelitian yang telah dilakukan tidak hanya berhenti pada pencapaian aspek teknis komputasi semata. Lebih dari itu, keberhasilan eksperimen ini merupakan sebuah wujud nyata dari implementasi dan realisasi amanah ilmiah yang selaras dengan nilai-nilai luhur yang terkandung dalam Al-Qur'an.

Pada hakikatnya, keberhasilan model MLP dalam mengklasifikasikan data rekam medis pasien secara akurat merupakan bentuk respons terhadap perintah Allah SWT untuk merenungkan tanda-tanda kekuasaan-Nya di alam semesta, termasuk dalam tubuh manusia dan ilmu pengetahuan. Hal ini sejalan dengan firman Allah SWT dalam QS. An-Nahl ayat 69:

يَا أَيُّهَا النَّاسُ قَدْ جَاءَكُمْ مَوْعِظَةٌ مِنْ رَبِّكُمْ وَشِفَاءٌ لِمَا فِي الصُّدُورِ وَهُدًى وَرَحْمَةٌ لِّلْمُؤْمِنِينَ ۚ ثُمَّ كُلُوا مِن كُلِّ الثَّمَرَاتِ فَاسْلُكُوا سَبِيلَ رَبِّك ۚ ذُلَّلَا ۚ يَخْرُجُ مِنْ بُطُونِهَا شَرَابٌ مُّخْتَلِفٌ أَلْوَانُهُ فِيهِ شِفَاءٌ لِّلنَّاسِ ۚ إِنَّ فِي ذَٰلِكَ لَآيَةً لِّقَوْمٍ يَتَفَكَّرُونَ

“Kemudian makanlah dari segala (macam) buah-buahan, lalu tempuhlah jalan Tuhanmu yang telah dimudahkan (bagimu).” Dari perut lebah itu keluar minuman (madu) yang bermacam-macam warnanya, di dalamnya terdapat obat yang menyembuhkan bagi manusia. Sungguh, pada yang demikian itu benar-benar terdapat tanda (kebesaran Allah) bagi orang yang berpikir.” (Q.S An-Nahl ayat 69.)

Melalui penelitian ini, ayat tersebut diimplementasikan melalui proses ‘*tafakkur*’ ilmiah. Peneliti memanfaatkan data rekam medis—yang merepresentasikan kondisi klinis pasien—lalu mengolahnya menggunakan arsitektur jaringan saraf tiruan untuk mengeksplorasi sebuah sistem pendukung keputusan medis (*clinical decision support system*). Aplikasi yang dihasilkan bertindak sebagai media ikhtiar modern untuk menemukan sarana deteksi dini yang cepat dan akurat, yang secara substansi esensial selaras dengan semangat mencari *syifa*’ (penyembuh atau solusi kesehatan) bagi umat manusia melalui perantara efisiensi teknologi.

Di samping itu, keberhasilan implementasi sistem ini tidak dapat berdiri sendiri tanpa adanya integrasi lintas sektoral. Proses perwujudan teknologi ini secara langsung telah mengamalkan prinsip kolektivitas dan sinergisitas yang digariskan oleh Allah SWT dalam QS. Al-Mā’idah ayat 2:

وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ ۚ وَاتَّقُوا اللَّهَ ۖ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ

“Tolong-menolonglah kamu dalam kebajikan dan takwa, dan jangan tolongmenolong dalam berbuat dosa dan permusuhan. Bertakwalah kepada Allah, sesungguhnya Allah sangat berat siksaan-Nya.” (QS. Al-Mā’idah: 2)

Berdasarkan Tafsir Ringkas Kementerian Agama Republik Indonesia, ayat tersebut menegaskan kewajiban bagi orang-orang mukmin untuk saling bahu-membahu dalam kebajikan dan ketakwaan demi kemaslahatan serta kebahagiaan

bersama. Sebaliknya, umat Islam dilarang keras untuk saling mendukung dalam perbuatan dosa maupun pelanggaran hukum, serta diperintahkan untuk senantiasa bertakwa agar terhindar dari siksaan Allah yang amat pedih.

Dalam konteks operasional penelitian ini, perintah tolong-menolong dalam kebajikan (*al-birr*) tersebut diterjemahkan ke dalam bentuk kolaborasi antardisiplin ilmu. Penelitian ini mempertemukan keahlian Teknik Informatika—khususnya dalam bidang komputasi cerdas dan kecerdasan buatan—dengan ranah kedokteran serta ilmu kesehatan masyarakat yang berfokus pada penanganan penyakit pernapasan (*asma*). Sinergi interdisipliner ini mematahkan batasan ego keilmuan demi sebuah tujuan mulia, yaitu menghadirkan inovasi yang mampu membawa kemaslahatan nyata (*kemaslahatan umat*). Dengan demikian, sistem yang telah diuji ini siap memberikan kontribusi konkret dalam membantu meringankan beban kerja tenaga medis di fasilitas kesehatan, meminimalkan risiko keterlambatan diagnosis pada pasien, serta mengoptimalkan efisiensi manajemen data pada instansi rumah sakit di masa yang akan datang.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, dapat disimpulkan bahwa metode Multilayer Perceptron (MLP) mampu digunakan untuk mendeteksi indikasi penyakit asma berdasarkan data rekam medis. Hasil penelitian menunjukkan bahwa performa model dipengaruhi oleh konfigurasi arsitektur jaringan dan keseimbangan data. pada kondisi balanced menggunakan SMOTE diperoleh rata-rata, Precision 83,84%, Recall 74,95%, dan F1-Score 78,92%. Hasil tersebut menunjukkan bahwa SMOTE mampu meningkatkan kemampuan model dalam mengenali kelas minoritas yang ditunjukkan oleh peningkatan nilai Recall dan F1-Score. Konfigurasi arsitektur 20-64-32-16-1 pada hidden layer 3 dengan skenario model ke 8, kondisi data balanced menghasilkan performa terbaik dengan Precision 84,38%, Recall 78,74%, dan F1-Score 81,22%. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi penyeimbangan data menggunakan SMOTE serta kapasitas neuron yang lebih besar mampu meningkatkan performa model MLP dalam mendeteksi indikasi asma. Selain itu, peningkatan jumlah neuron memberikan pengaruh yang lebih konsisten dibandingkan penambahan hidden layer dalam menghasilkan model klasifikasi yang optimal.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat digunakan untuk pengembangan penelitian selanjutnya, yaitu:

1. Menambah jumlah data dan menggunakan dataset yang berasal dari data rekam medis nyata agar model dapat mempelajari pola yang lebih beragam dan memiliki kemampuan generalisasi yang lebih baik.
2. Membandingkan performa Multilayer Perceptron (MLP) dengan algoritma machine learning maupun deep learning lainnya, seperti Random Forest, XGBoost, Deep Neural Network (DNN), atau Long Short-Term Memory (LSTM).
3. Mengembangkan sistem yang telah dibuat menjadi aplikasi yang dapat digunakan secara langsung sebagai sistem pendukung keputusan untuk membantu proses deteksi dini indikasi penyakit asma.

DAFTAR PUSTAKA

- Adir, Y., Saliba, W., Beurnier, A., & Humbert, M. (2021). Asthma and COVID-19: An update. *European Respiratory Review*, 30(162), 210152. <https://doi.org/10.1183/16000617.0152-2021>
- Agache, I., Eguiluz-Gracia, I., Cojanu, C., Laculiceanu, A., Del Giacco, S., Zemelka-Wiacek, M., Kosowska, A., Akdis, C. A., & Jutel, M. (2021). Advances and highlights in asthma in 2021. *Allergy*, 76(11), 3390–3407. <https://doi.org/10.1111/all.15054>
- Alkobaisi, S., Safdar, M. F., Pałka, P., & Abu Ali, N. A. (2025). Artificial Intelligence Algorithms in Asthma Management: A Review of Data Engineering, Predictive Models, and Future Implications. *Applied Sciences*, 15(7), 3609. <https://doi.org/10.3390/app15073609>
- Badnjevic, A., Gurbeta, L., Cifrek, M., & Marjanovic, D. (2016). Classification of asthma using artificial neural network. *2016 39th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 387–390. <https://doi.org/10.1109/MIPRO.2016.7522173>
- Bridge, J., Blakey, J. D., & Bonnett, L. J. (2020). A systematic review of methodology used in the development of prediction models for future asthma exacerbation. *BMC Medical Research Methodology*, 20(1), 22. <https://doi.org/10.1186/s12874-020-0913-7>
- Brunn, B., Hapfelmeier, A., Jörres, R. A., Schultz, K., & Schneider, A. (2023). Development of a diagnostic score using FeNO and symptoms to predict asthma. *Respiratory Medicine*, 215, 107299. <https://doi.org/10.1016/j.rmed.2023.107299>
- Budiarto, A., Tsang, K. C. H., Wilson, A. M., Sheikh, A., & Shah, S. A. (2023). Machine Learning–Based Asthma Attack Prediction Models From Routinely Collected Electronic Health Records: Systematic Scoping Review. *JMIR AI*, 2, e46717. <https://doi.org/10.2196/46717>
- Chatzimichail, E., Rigas, A., Paraskakis, E., & Chatzimichail, A. (2010). Diagnosis of Asthma Severity Using Artificial Neural Networks. In P. D. Bamidis & N. Pallikarakis (Eds.), *XII Mediterranean Conference on Medical and Biological Engineering and Computing 2010* (Vol. 29, pp. 600–603). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-13039-7_151

- Chen, M.-H., Lee, G., & Hung, L.-P. (2025). AI-Driven Data Analysis for Asthma Risk Prediction. *Healthcare*, 13(7), 774. <https://doi.org/10.3390/healthcare13070774>
- Da Silva, E. M., Dewi, Y. S., Marâ€™ah, E. M., & Hasanudin, H. (2023). Latihan Pernapasan dalam Meningkatkan Kontrol Asma dan Kualitas Hidup Pasien Asma Dewasa. *Jurnal Keperawatan Silampari*, 6(2), 908–920. <https://doi.org/10.31539/jks.v6i2.4495>
- Daniel, I., Limas Ptr, A. F., & Ichsan, A. (2024). Klasifikasi Risiko Penyakit Jantung Dengan Multilayer Perceptron. *Data Sciences Indonesia (DSI)*, 4(1), 78–82. <https://doi.org/10.47709/dsi.v4i1.4667>
- García-Marcos, L., Chiang, C.-Y., Asher, M. I., Marks, G. B., El Sony, A., Masekela, R., Bissell, K., Ellwood, E., Ellwood, P., Pearce, N., Strachan, D. P., Mortimer, K., Morales, E., Ahmetaj, L. N., Ajeagah, G. A., Alkhayer, G., Alomary, S. A., Ambriz-Moreno, M. J., Arias-Cruz, A., ... Zhjeqi, V. (2023). Asthma management and control in children, adolescents, and adults in 25 countries: A Global Asthma Network Phase I cross-sectional study. *The Lancet Global Health*, 11(2), e218–e228. [https://doi.org/10.1016/S2214-109X\(22\)00506-X](https://doi.org/10.1016/S2214-109X(22)00506-X)
- Gereda, J. E., De Arruda-Chaves, E., Larco, J., Matos, E., & Runzer, F. (2024). Asma grave: Fisiopatología, diagnóstico y tratamiento. *Revista Alergia México*, 71(2), 114–127. <https://doi.org/10.29262/ram.v71i2.1283>
- Hussain, K., Mehmood, K., Yujun, S., Badshah, T., Anees, S. A., Shahzad, F., Nooruddin, Ali, J., & Bilal, M. (2025). Analysing LULC transformations using remote sensing data: Insights from a multilayer perceptron neural network approach. *Annals of GIS*, 31(3), 473–500. <https://doi.org/10.1080/19475683.2024.2343399>
- Janssen, H. (2022). Comment on Cabrera et al. A User-Friendly Tool to Characterize the Moisture Transfer in Porous Building Materials: FLoW1D. *Appl. Sci.* 2020, 10, 5090. *Applied Sciences*, 12(3), 1123. <https://doi.org/10.3390/app12031123>
- Kothalawala, D. M., Kadalayil, L., Weiss, V. B. N., Kyyaly, M. A., Arshad, S. H., Holloway, J. W., & Rezwan, F. I. (2020). Prediction models for childhood asthma: A systematic review. *Pediatric Allergy and Immunology*, 31(6), 616–627. <https://doi.org/10.1111/pai.13247>
- Kothalawala, D. M., Murray, C. S., Simpson, A., Custovic, A., Tapper, W. J., Arshad, S. H., Holloway, J. W., Rezwan, F. I., & STELAR/UNICORN investigators. (2021). Development of childhood asthma prediction models using machine learning approaches. *Clinical and Translational Allergy*, 11(9), e12076. <https://doi.org/10.1002/clt2.12076>

- McDowell, P. J., & Heaney, L. G. (2020). Different endotypes and phenotypes drive the heterogeneity in severe asthma. *Allergy*, 75(2), 302–310. <https://doi.org/10.1111/all.13966>
- Mortimer, K., Reddel, H. K., Pitrez, P. M., & Bateman, E. D. (2022). Asthma management in low and middle income countries: Case for change. *European Respiratory Journal*, 60(3), 2103179. <https://doi.org/10.1183/13993003.03179-2021>
- Nimas Ratna Sari & Yulaikha Mar'atullatifah. (2023). PENERAPAN MULTILAYER PERCEPTRON UNTUK IDENTIFIKASI KANKER PAYUDARA. *Jurnal Cakrawala Ilmiah*, 2(8), 3261–3268. <https://doi.org/10.53625/jcijurnalcakrawailmiah.v2i8.5519>
- Ojanguren, I., Quirce, S., Bobolea, I., Pérez De Llano, L., & Del Pozo, V. (2025). Phenotyping Asthma Exacerbations: One Step Further in the Management of Severe Asthma. *Journal of Investigational Allergy and Clinical Immunology*, 35(1), 1–11. <https://doi.org/10.18176/jiaci.1043>
- Qaid, E. Y. A., & Long, I. (2025). Asthma unravelled: A comprehensive review of epidemiology, phenotypes, pathophysiology, and emerging therapies. *The Egyptian Journal of Bronchology*, 19(1), 82. <https://doi.org/10.1186/s43168-025-00443-w>
- Qur'an Kemenag*. (n.d.). Retrieved April 1, 2026, from <https://quran.kemenag.go.id/quran/per-ayat/surah/10?from=57&to=57>
- Rabe, A. P., Loke, W. J., Gurjar, K., Brackley, A., & Lucero-Prisno Iii, D. E. (2023). Global Burden of Asthma, and Its Impact on Specific Subgroups: Nasal Polyps, Allergic Rhinitis, Severe Asthma, Eosinophilic Asthma. *Journal of Asthma and Allergy, Volume 16*, 1097–1113. <https://doi.org/10.2147/JAA.S418145>
- Rabie El Kharoua. (n.d.).  *Asthma Disease Dataset*  [Dataset]. Kaggle. <https://doi.org/10.34740/KAGGLE/DSV/8669080>
- Sagheb, E., Wi, C.-I., King, K. S., Agnikula Kshatriya, B. S., Ryu, E., Liu, H., Park, M. A., Seol, H. Y., Overgaard, S. M., Sharma, D. K., Juhn, Y. J., & Sohn, S. (2025). AI model for predicting asthma prognosis in children. *Journal of Allergy and Clinical Immunology: Global*, 4(2), 100429. <https://doi.org/10.1016/j.jacig.2025.100429>
- Tan, L., Nguyen, N., Lopez, E., Peverini, D., Shedd, M., Alismail, A., & Nguyen, H. (2025). Artificial Intelligence in the Management of Asthma: A Review of a New Frontier in Patient Care. *Journal of Asthma and Allergy, Volume 18*, 1179–1191. <https://doi.org/10.2147/JAA.S535264>

- Xiang, Y., Ji, H., Zhou, Y., Li, F., Du, J., Rasmy, L., Wu, S., Zheng, W. J., Xu, H., Zhi, D., Zhang, Y., & Tao, C. (2020a). Asthma Exacerbation Prediction and Risk Factor Analysis Based on a Time-Sensitive, Attentive Neural Network: Retrospective Cohort Study. *Journal of Medical Internet Research*, 22(7), e16981. <https://doi.org/10.2196/16981>
- Xiang, Y., Ji, H., Zhou, Y., Li, F., Du, J., Rasmy, L., Wu, S., Zheng, W. J., Xu, H., Zhi, D., Zhang, Y., & Tao, C. (2020b). Asthma Exacerbation Prediction and Risk Factor Analysis Based on a Time-Sensitive, Attentive Neural Network: Retrospective Cohort Study. *Journal of Medical Internet Research*, 22(7), e16981. <https://doi.org/10.2196/16981>