

SKRIPSI

MULTI KLASIFIKASI PENYAKIT DIABETES DENGAN MENGUNAKAN *MACHINE LEARNING RANDOM FOREST*

Diajukan Sebagai Syarat Medapatkan Gelar Sarjana Strata Satu (S1) Teknik
Pada Program Studi Teknik Elektro



Disusun oleh:
Asep Nugraha
NIM
41037002241018

**PROGRAM STUDI TEKNIK ELEKTRO
FAKULTAS TEKNIK DAN PERTANIAN
UNIVERSITAS ISLAM NUSANTARA
2026**

LEMBAR KEASLIAN SKRIPSI

Yang Bertandatangan dibawah ini :

Nama : Asep Nugraha

NIM : 41037002241018

Program Studi : Teknik Elektro

Menyatakan bahwa Skripsi yang berjudul :

“MULTI KLASIFIKASI PENYAKIT DIABETES DENGAN MENGGUNAKAN *MACHINE LEARNING RANDOM FOREST*“

Dibuat dengan sebenar – benarnya dan dalam keadaan sehat jasmani dan rohani. Skripsi ini dibuat dari penelitian, dan pemaparan hasil saya sendiri. Untuk melengkapi dan memenuhi pernyataan menjadi Sarjana (S1) pada Fakultas Teknik dan Pertanian Universitas Islam Nusantara. Sepanjang yang saya ketahui buku skripsi ini bukan merupakan tiruan atau duplikasi dari buku skripsi yang sudah di publikasikan dan atau pernah di pakai untuk mendapatkan Jenjang Sarjana (S1) dilingkungan Fakultas Teknik dan Pertanian ataupun Fakultas lain di Universitas Islam Nusantara ataupun dilingkungan Perguruan Tinggi lainnya baik didalam Negeri ataupun diluar Negeri serta di Instansi manapun. Kecuali bagian yang bersumber pada Informasi yang saya cantumkan sebagai mana mestinya.

Bandung, 04 Mei 2026
Yang Menyatakan,

Asep Nugraha
41037002241018

Lembar Pengesahan

Lembar Pengesahan

BIO DATA PENULIS



Nama : Asep Nugraha
Tempat, Tanggal Lahir : Bandung, 09 Oktober 1985
Telepon : +62 812 2377 1555
Email : asep.nugraha9@gmail.com
Riwayat Pendidikan : Sekolah Dasar Negeri Margasari 01
Sekolah Lanjutan Tingkat Pertama Negeri 48 Bandung
Sekolah Menengah Umum Bhina Dharma 2

KATA PENGANTAR

□□□□□□□□□□ □□□□□□□□□□□□ □□□□□ □□□□□□

Dengan Menyebut Nama Allah yang Maha Pengasih Lagi Maha Penyayang.

Segala Puji hanya Milik Allah SWT. Penguasa alam semesta. Solawat serta Salam penulis panjatkan kepada Jungjunan alam Nabi Muhammad SAW. Atas Anugrah berkah, rahmat dan karunianya penulis diberikan kesehatan lahir dan batin, serta atas izinnya penulis dapat menyelesaikan Skripsi yang berjudul “Multi Klasifikasi Penyakit Diabetes Dengan Menggunakan *Machine Learning Random Forest*”. sejalan dengan proses akademis yang dilalui.

Penulis menyadari dengan segala kelemahan dan keterbatasan yang dilalui dalam tahapan proses penulisan skripsi ini, masih jauh dari kata Sempurna. Dimana sebagai makhluk tempatnya Salah dan Khilaf. Kebenaran hanya milik Allah SWT.

Dalam peroses penyusunan skripsi ini penulis tidak lepas dari peran serta Allah SWT, yang dengan Maha Pengasih dan Penyayang. Yang telah mengirimkan orang-orang pilihan nya untuk membantu penulis menyelesaikan penulisan skripsi ini tepat waktu. Pada kesempatan yang sangat mulia ini penulis ingin menyampaikan rasa terima kasih yang sebesar besarnya kepada :

1. Ayahanda tercinta Bapa Tata Bin Abas serta Ibunda Tercinta Mamah Rodiah Bin Aba Djaja. Yang dengan doa-doanya yang dilantarkan pada 1/3 malamnya. *Mamah bapa, alhamdulillah aa Lulus Sarjana mah pa. Ieu kanggo mamah sareng bapa. Saalit tanda bakti aa ka mamah sareng bapa. Mugia di hapunten. Moal aya aa pami teu aya mamah sareng bapa. Hatur nuhun.*
2. Istri ku Tersayang teman hidup sejutiku Susan Srimulyati, yang telah Allah SWT kirimkan kepadaku untuk menemani dan melewati setiap tangga kehidupan baik suka maupun duka. Yang dengan segala ketulusan dan kerendahan hatinya yang sangat istimewa dan selalu mendukung serta menemani setiap langkah dalam hidupku, yang selalu memberi warna dalam setiap perjalanan hidupku. *Anu degdegan ngajapkeun abah sidang skripsi. Hatur nuhun ibu, selalu ada buat abah. Lope Badag bu.*
3. Teteh Diana Aghra Kusuma Nagara, Anak Abah tersayang kebanggaan abah dan Ibu, Terima kasih sudah memberikan arti Tanggung Jawab kepada abah dan ibu. *Buah Ati Kembang Soca Pupunden Ati. Mugia teteh Aghra tiasa langkung sukses langkung Jembar Hatena solehah lahir batinna ti abah sareng ibu. Pinter cageur tur bener.*
4. Dosen Pembimbing I dan Dosen Pembimbing II, Ibu Osphanie Mentari Primadianti, S.T., M.T., M. Eng dan Bapak Muhammad Zimamul Adil, M.Si. dengan segenap dedikasahnya telah banyak membantu penulis menyusun dan menyelesaikan Skripsi tepat waktu.
5. Kaprodi Fakultas Teknik Elektro Bapak Agung Muhamad Toha, S.ST., M.T yang telah banyak mensupport penulis dalam penyelesaian proses proses akademi.
6. Tim penguji bapak Dr. Iksal Rachman, M.T. dan ketua Sidang Bapak Galih, S.T., M.Kom. yang banyak memberi masukan dan pengalaman hidup kepada penulis.

7. Rektor Universitas Islam Nusantara Bapak Prof. Dr. Endang Komara. M.Si. serta Dekan Fakultas Teknik dan Pertanian Ibu Dr. Debby Ustari, S.P., M.P.
8. Mang Iing (Lingga K. Octaviansyah, ST., MT.) Mang Koko (Koko Jatmiko, ST.) Mang Firman (Ir. Firman Joeanda, MT.) Om Adrian (Ir. Adrian Priyana, ST.) yang selalu mengingatkan dan banyak memberi Motivasi Penulis untuk segera menyelesaikan studi.
9. Keluarga besar Teh Rina Febriyani, M.Ag, yang selalu suport untuk berdiskusi bersama penulis dalam penyelesaian Skripsi.
10. Uyt Suma Natawijaya Surya Ningrat, Kh Burhan Ibnu Bin Warta Kusumah, Keluarga Besar Hanjung Nanjung Darusalam Bapak H. Tonton Sutandi bersama warga Jamaah Griya darusalam Pimpinan Pondok Pesantren Mahabatul Aulia Bapak KH. Fuad Ginan.
11. Kaka dan adik adik tercinta, Teteh Ina Rosina , Teteh Dahlia, Intan Permatasari dan Fahmi Mochamad Rijal.
12. Rekan Rekan angkatan beserta adik Kelas Fakultas Teknik Elektro, yang dengan kebersamaan saling mendukung untuk terus memberikan semangat kepada penulis. *Hatur nuhun dulurrrr.*
13. Semua Pihak yang telah banyak berkontribusi kepada Penulis yang tidak dapat penulis sebutkan satu persatu. Semoga amal baikan nya dibalas Allah Swt.

Ketidak sempurnaan dalam penulisan skripsi ini, penulis berharap semua pihak dapat memberikan Kritik dan saran yang positif bagi kemajuan penulis dimasa yang akan datang. Semoga Skripsi Ini bermanfaat bagi semua pihak dan dapat dijadikan rujukan bagi Pengembang teknologi dibidang Elektro ataupun bagi Pembaca dimasa yang akan datang.

Bandung, 04 Mei 2026
Penulis,

Asep Nugraha
41037002241018

ABSTRAK

Diabetes melitus merupakan penyakit metabolik kronis yang prevalensinya terus meningkat dan menjadi beban kesehatan global yang signifikan. Permasalahan utama dalam penanganannya terletak pada keterbatasan metode konvensional dalam mengidentifikasi fase transisi (prediabetes), yang seringkali menyebabkan keterlambatan intervensi medis. Oleh karena itu, diperlukan pendekatan berbasis teknologi yang mampu melakukan klasifikasi kondisi pasien secara lebih objektif, sistematis, dan berbasis data.

Penelitian ini bertujuan untuk mengkaji penerapan algoritma machine learning dalam melakukan klasifikasi *multi-class* penyakit diabetes. Klasifikasi difokuskan pada tiga kategori utama, yaitu *non-diabetic*, *diabetic*, dan *predict diabetic*. Selain itu, penelitian ini juga diarahkan untuk mengevaluasi kinerja masing-masing algoritma serta menentukan model yang paling optimal dalam mendukung proses diagnosis berbasis data.

Metodologi yang digunakan dalam penelitian ini bersifat eksperimental dengan memanfaatkan dataset sekunder yang diperoleh dari *platform Kaggle*. Data yang digunakan terdiri dari berbagai parameter klinis, seperti usia, indeks massa tubuh, tekanan darah, kadar glukosa, dan indikator lainnya. Tahapan pengolahan data meliputi proses pembersihan, transformasi, dan normalisasi, yang kemudian dilanjutkan dengan pembagian data ke dalam data latih dan data uji dengan rasio 80:20. Empat algoritma machine learning diterapkan, yaitu *Support Vector Machine*, *Random Forest*, *Decision Tree*, dan *Logistic Regression*, dengan evaluasi kinerja menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

Kerangka teoretis penelitian ini didasarkan pada konsep supervised learning dalam machine learning, khususnya pada pendekatan klasifikasi multi-kelas. Selain itu, pendekatan ensemble learning pada algoritma *Random Forest* digunakan untuk meningkatkan kemampuan generalisasi model melalui kombinasi beberapa pohon keputusan. Analisis juga mempertimbangkan relevansi fitur klinis sebagai variabel prediktor dalam mengidentifikasi pola yang berkaitan dengan kondisi diabetes.

Hasil penelitian menunjukkan bahwa algoritma *Random Forest* memiliki tingkat kinerja tertinggi dengan akurasi mencapai 99%, diikuti oleh *Decision Tree* sebesar 98%, *Support Vector Machine* sebesar 85%, dan *Logistic Regression* sebesar 79%. Selain itu, *Random Forest* menunjukkan kemampuan yang sangat baik dalam mendeteksi kategori prediabetes dengan nilai sensitivitas yang tinggi. Dengan demikian, dapat disimpulkan bahwa pendekatan berbasis *ensemble learning* memiliki keunggulan dalam klasifikasi multi-kelas penyakit diabetes dan berpotensi untuk dikembangkan sebagai sistem pendukung keputusan dalam bidang kesehatan berbasis data.

Kata Kunci: *Diabetes, Multi-klasifikasi, Machine Learning, Random Forest, Akurasi 99%.*

ABSTRACT

Diabetes mellitus is a chronic metabolic disease whose prevalence continues to increase and poses a significant global health burden. One of the main challenges in its management lies in the limitation of conventional methods to accurately identify the transitional phase (prediabetes), which often leads to delayed medical intervention. Therefore, a technology-based approach is required to enable objective, systematic, and data-driven classification of patient conditions.

This study aims to examine the implementation of machine learning algorithms for multiclass classification of diabetes. The classification focuses on three main categories: non-diabetic, diabetic, and predict diabetic. In addition, this research seeks to evaluate the performance of each algorithm and determine the most optimal model to support data-driven diagnostic decision-making.

The research methodology adopts an experimental approach using a secondary dataset obtained from Kaggle. The dataset consists of various clinical parameters, including age, body mass index (BMI), blood pressure, glucose level, and other relevant indicators. Data processing involves cleaning, transformation, and normalization, followed by data splitting into training (80%) and testing (20%) sets. Four machine learning algorithms are applied, namely Support Vector Machine (SVM), Random Forest (RF), Decision Tree (DT), and Logistic Regression (LR). Model performance is evaluated using accuracy, precision, recall, and F1-score metrics.

The theoretical framework of this study is based on supervised learning in machine learning, particularly multiclass classification approaches. Furthermore, ensemble learning principles in the Random Forest algorithm are utilized to enhance model generalization through the combination of multiple decision trees. The analysis also considers the relevance of clinical features as predictive variables in identifying patterns associated with diabetes conditions.

The results indicate that the Random Forest algorithm achieves the highest performance with an accuracy of 99%, followed by Decision Tree at 98%, Support Vector Machine at 85%, and Logistic Regression at 79%. Additionally, Random Forest demonstrates excellent capability in detecting prediabetes with a high recall value. In conclusion, ensemble learning-based approaches show superior performance in multiclass classification of diabetes and have strong potential to be developed as data-driven decision support systems in the healthcare domain.

Keywords: *Diabetes, Multi-classification, Machine Learning, Random Forest, 99% Accuracy.*

DAFTAR ISI

LEMBAR KEASLIAN SKRIPSI.....	ERROR! BOOKMARK NOT DEFINED.
LEMBAR PENGESAHAN.....	II
LEMBAR PENGESAHAN.....	IV
BIODATA PENULIS	ERROR! BOOKMARK NOT DEFINED.
KATA PENGANTAR	ERROR! BOOKMARK NOT DEFINED.
ABSTRAK.....	VIII
ABSTRACT	IX
DAFTAR ISI.....	X
DAFTAR TABEL.....	XII
DAFTAR GAMBAR	XIII
BAB I.....	1
PENDAHULUAN.....	1
1.1. LATAR BELAKANG MASALAH.....	1
1.2. RUMUSAN MASALAH.....	4
1.3. TUJUAN PENELITIAN	4
1.4. MANFAAT PENELITIAN.....	5
1.5. BATASAN MASALAH	5
1.6. KERANGKA BERPIKIR	6
BAB II.....	9
TINJAUAN PUSTAKA.....	9
2.1. KECERDASAN BUATAN (<i>ARTIFICIAL INTELLIGENCE</i>).....	9
2.2. <i>MACHINE LEARNING</i>	14
2.3. PERALATAN KERJA YANG DIGUNAKAN.....	16
2.4. PENGERTIAN PENYAKIT DIABETES	17
2.5. <i>FEATURE</i> KATEGORI PENYAKIT DIABETES.....	18
BAB III.....	21
METODOLOGI PENELITIAN	21
3.1. WAKTU PENELITIAN.....	21
3.2. SUMBER DATA	21
3.4. METODE PENGUMPULAN DATA.....	22
3.5. TAHAPAN PENELITIAN	22
3.6. TEKNIK ANALISIS DATA.....	23
BAB IV.....	27

HASIL DAN PEMBAHASAN	27
4.1. HASIL UJI KLASIFIKASI MODEL <i>MACHINE LEARNING</i>	27
4.2. PEMBAHASAN	43
BAB V	64
PENUTUP	64
5.1. KESIMPULAN	64
5.2. SARAN	65
LAMPIRAN	67
DAFTAR PUSTAKA	70

DAFTAR TABEL

Tabel 1. Jadwal Penelitian	26
Tabel 2. Hasil Pengujian SVM (Support Vector Machine)	34
Tabel 3. Hasil Pengujian Random Forest.....	36
Tabel 4. Hasil Pengujian Decision Tree.....	38
Tabel 5. Hasil Pengujian Logistic Regression	40
Tabel 6. Pemetaan Label Kelas	48
Tabel 7. Pemetaan Klasifikasi Model dan Karakteristik Klinis	55
Tabel 8. Akurasi Algoritma.....	61

DAFTAR GAMBAR

Gambar 1. Alur Proses Artificial Intelligence (AI) Bekerja	9
Gambar 2. Alur Penelitian	24
Gambar 3. Proses Pengujian data sheet pada coding Anaconda.....	27
Gambar 4. Hasil Pengujian SVM Pada Coding Anaconda.....	33
Gambar 5. Hasil Pengujian Random Forest Coding Anaconda.....	35
Gambar 6. Hasil Pengujian Decision Tree Pada Coding Anaconda.....	38
Gambar 7. Hasil Pengujian Logic Regresion Pada Coding Anaconda.....	41
Gambar 8. Performa Akurasi Algoritma Data Sheet Pada Coding Anaconda.....	61

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Perkembangan teknologi informasi dan data dalam satu dekade terakhir telah memberikan dampak signifikan terhadap dunia kesehatan. Salah satu masalah kesehatan global yang masih menjadi perhatian utama hingga saat ini adalah diabetes melitus, yaitu gangguan metabolik kronis yang ditandai dengan meningkatnya kadar glukosa darah akibat gangguan pada sekresi atau kerja insulin. Berdasarkan laporan Indonesia menempati peringkat ke-7 dari 10 negara dengan jumlah penderita tertinggi, yaitu sebesar 11,3% tahun 2023 (Kendek et al., 2023), jumlah penderita diabetes di dunia telah melampaui 422 juta jiwa (Dinda Yosi Permana, 2024) dan angka ini diprediksi terus meningkat secara konsisten setiap tahunnya. Peningkatan ini tidak hanya terjadi di negara maju, tetapi juga di negara berkembang seperti Indonesia, di mana pola hidup modern dan perubahan gaya konsumsi turut berkontribusi terhadap peningkatan prevalensi penyakit ini.

Fenomena ini tidak hanya terjadi di negara-negara maju, tetapi juga di negara berkembang seperti Indonesia. Berdasarkan data dari Kementerian Kesehatan Republik Indonesia, prevalensi diabetes mengalami peningkatan signifikan dalam dua dekade terakhir, terutama di wilayah perkotaan. Gaya hidup modern yang cenderung tidak sehat, pola makan tinggi kalori, konsumsi gula berlebih, serta kurangnya aktivitas fisik menjadi faktor utama yang memperburuk kondisi tersebut.

Selain faktor gaya hidup, perubahan demografis seperti peningkatan usia harapan hidup dan faktor genetik juga turut memperbesar risiko terjadinya diabetes. Kombinasi faktor-faktor ini menjadikan diabetes sebagai salah satu penyakit tidak menular dengan tingkat beban ekonomi dan sosial yang tinggi. Pasien dengan diabetes tidak hanya membutuhkan penanganan medis jangka panjang, tetapi juga pemantauan rutin terhadap kadar glukosa dan penyesuaian terapi secara berkelanjutan. Oleh karena itu, kehadiran sistem berbasis teknologi yang mampu

membantu proses klasifikasi dan diagnosis menjadi kebutuhan yang semakin mendesak.

Di sinilah peran *machine learning* menjadi sangat relevan. *Machine learning* merupakan cabang dari kecerdasan buatan yang memungkinkan sistem komputer belajar dari data dan mengenali pola tanpa harus diprogram secara eksplisit (Maulani et al., 2025). Dalam konteks medis, *machine learning* dapat digunakan untuk mengolah data pasien yang kompleks mencakup variabel fisiologis seperti tekanan darah, kadar glukosa, indeks massa tubuh (BMI), usia, serta kadar insulin untuk mengidentifikasi pola yang dapat digunakan dalam proses klasifikasi penyakit diabetes.

Penerapan *machine learning* dalam klasifikasi penyakit diabetes juga memiliki relevansi yang kuat (Marlim et al., 2022). Hal ini terkait dengan integrasi antara sistem pengolahan data, sensor elektronik medis, dan perangkat pemantauan otomatis. Sistem cerdas yang dirancang dengan algoritma *machine learning* dapat diimplementasikan pada perangkat *embedded system*, *wearable medical devices*, atau sistem monitoring berbasis IoT (*Internet of Things*). Misalnya, sensor kadar glukosa yang terhubung dengan sistem pengolah data berbasis ML dapat memberikan hasil analisis *real-time* mengenai kondisi pasien, sekaligus memperkirakan tipe diabetes yang mungkin dialami.

Diabetes merupakan penyakit yang kompleks karena memiliki berbagai tipe dengan karakteristik dan faktor risiko yang berbeda dengan *multi-class*, yaitu 0= *non diabetic*, 1= *diabetic*, 2= *predict diabetic* (Putri, 2025). Penentuan tipe diabetes sangat penting dalam proses penatalaksanaan, karena kesalahan klasifikasi dapat berakibat pada pemberian terapi yang tidak tepat dan memperburuk kondisi pasien. Namun, dalam praktik klinis, diagnosis dan klasifikasi diabetes seringkali bergantung pada analisis manual terhadap hasil laboratorium serta interpretasi subjektif tenaga medis, yang berpotensi menimbulkan bias atau ketidaktepatan diagnosis.

Perbedaan karakteristik antar tipe diabetes menjadikan proses tidak dapat diseragamkan. Setiap tipe membutuhkan pendekatan terapi, pengawasan kadar glukosa, dan strategi pengelolaan risiko yang berbeda. Kesalahan dalam mengidentifikasi jenis diabetes dapat menimbulkan dampak serius, seperti penggunaan terapi obat yang tidak sesuai, keterlambatan dalam pemberian insulin, atau bahkan peningkatan komplikasi kronis seperti nefropati, retinopati, dan penyakit kardiovaskular. Oleh karena itu, klasifikasi yang akurat merupakan langkah awal yang sangat penting dalam pengelolaan penyakit diabetes secara efektif.

Selain itu, perkembangan volume data medis di rumah sakit modern semakin besar dan beragam, mencakup data hasil pemeriksaan laboratorium, rekam medis elektronik, citra medis, hingga data sensorik dari perangkat kesehatan digital. Analisis manual terhadap data sebanyak itu menjadi tidak efisien dan berpotensi menimbulkan bias interpretasi. Dalam situasi ini, dibutuhkan suatu pendekatan berbasis teknologi yang mampu membantu proses klasifikasi secara otomatis, objektif, dan berbasis pola data yang akurat.

Keunikan penelitian ini terletak pada penerapan *multi-class classification* yang mengintegrasikan berbagai algoritma ML untuk memperoleh model terbaik melalui proses evaluasi yang ketat menggunakan metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, penelitian ini berupaya menekankan peran data medis sebagai aset penting dalam pengambilan keputusan berbasis bukti (*evidence-based decision making*).

Dengan demikian, penelitian mengenai “Multi Klasifikasi Penyakit Diabetes dengan Menggunakan *Machine Learning Random Forest*” diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi dini berbasis teknologi, memperkaya literatur akademik di bidang data *science* kesehatan, serta membuka peluang penerapan kecerdasan buatan dalam sistem pelayanan medis di masa mendatang.

1.2. Rumusan Masalah

Dari latar belakang masalah yang telah dijelaskan di atas, didapatkan rumusan masalah adalah sebagai berikut:

1. Bagaimana penerapan pendekatan *machine learning random forest* dalam proses multi-klasifikasi penyakit diabetes dipahami dari perspektif teoritis dan praktis dalam teknik elektro?
2. Bagaimana persepsi dan pengalaman para ahli atau praktisi kesehatan terhadap penggunaan *machine learning random forest* dalam mendukung klasifikasi jenis penyakit diabetes?
3. Faktor-faktor apa saja yang memengaruhi efektivitas penerapan *machine learning random forest* dalam konteks klasifikasi multi-kelas penyakit diabetes?

1.3. Tujuan Penelitian

Adapun rumusan masalah yang telah disebutkan di atas, maka tujuan penelitian ini adalah sebagai berikut:

1. Untuk menganalisis konsep dan prinsip penerapan pendekatan *machine learning random forest* dalam proses multi-klasifikasi penyakit diabetes dipahami dari perspektif teoritis dan praktis dalam teknik elektro.
2. Untuk mengidentifikasi kelebihan, keterbatasan, serta tantangan dalam implementasi *machine learning random forest* pada sistem klasifikasi penyakit diabetes.
3. Untuk memberikan pemahaman komprehensif mengenai potensi penerapan machine learning sebagai inovasi teknologi dalam sistem pendukung keputusan medis.

1.4. Manfaat Penelitian

1. Manfaat Akademis

Penelitian ini diharapkan dapat memperkaya kajian akademik di bidang ilmu komputer, kesehatan, dan kecerdasan buatan dengan pendekatan kualitatif. Hasil penelitian ini dapat menjadi referensi teoritis bagi peneliti selanjutnya yang ingin menelusuri hubungan antara penerapan *machine learning random forest* dan praktik klasifikasi penyakit secara lebih mendalam pada bidang teknik elektro.

2. Manfaat Praktis

Hasil penelitian dapat memberikan wawasan kepada praktisi kesehatan dan pengembang sistem mengenai bagaimana penerapan *machine learning random forest* dapat diintegrasikan ke dalam proses diagnosis dan klasifikasi penyakit diabetes. Temuan ini juga dapat menjadi acuan dalam pengembangan kebijakan digitalisasi kesehatan di masa depan. Secara sosial, penelitian ini diharapkan meningkatkan kesadaran mengenai pentingnya pemanfaatan teknologi cerdas dalam mendukung pelayanan kesehatan yang lebih efisien dan tepat sasaran. Dari sisi teknologi, hasil penelitian ini dapat memperkuat arah pengembangan sistem kecerdasan buatan yang etis, adaptif, dan berorientasi pada kebutuhan manusia terutama pada kajian teknik elektro.

1.5. Batasan Masalah

Agar penelitian ini lebih terarah dan tidak meluas dari tujuan utama, maka diperlukan pembatasan ruang lingkup penelitian. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Jenis penyakit yang dikaji terbatas pada diabetes melitus, yang meliputi tiga kategori utama, yaitu *multi-class*, yaitu 0= *non diabetic*, 1= *diabetic*, 2= *predict diabetic*. Penyakit lain yang memiliki gejala serupa tidak termasuk dalam ruang lingkup penelitian ini.

2. Data yang digunakan dalam penelitian ini berasal dari dataset sekunder yang berisi parameter klinis umum seperti kadar glukosa, tekanan darah, indeks massa tubuh (BMI), kadar insulin, serta usia pasien. Penelitian ini tidak melakukan pengambilan data primer secara langsung dari pasien.
3. Pendekatan penelitian bersifat kualitatif-deskriptif, yaitu dengan menganalisis hasil klasifikasi yang dihasilkan oleh algoritma machine learning untuk memahami pola dan karakteristik dari tiap tipe diabetes. Fokus penelitian bukan pada optimasi performa algoritma secara kuantitatif, melainkan pada interpretasi hasil klasifikasi dan relevansinya terhadap karakteristik medis.
4. Algoritma *machine learning* yang digunakan terbatas pada beberapa metode utama, yaitu *SVM (Support Vector Machine)*, *RF (Random Forest)*, *DT (Decision Tree)*, *LR (Logistic Regression)*. Algoritma lain di luar ketiga metode tersebut tidak menjadi fokus analisis mendalam dalam penelitian ini.
5. Penelitian ini tidak mencakup implementasi sistem berbasis perangkat keras secara langsung, seperti integrasi model ke dalam sensor atau alat medis elektronik. Namun, penelitian ini membahas potensi pengembangan dan penerapan model dalam sistem elektro-medis di masa depan sebagai rekomendasi lanjutan.
6. Penelitian ini hanya berfokus pada multi-klasifikasi penyakit diabetes, bukan pada prediksi komplikasi atau prognosis jangka panjang.

1.6. Kerangka Berpikir

Penelitian ini disusun dengan landasan pemikiran bahwa meningkatnya prevalensi penyakit diabetes memerlukan pendekatan ilmiah berbasis teknologi yang mampu mendukung proses diagnosis dan klasifikasi secara objektif. Dalam konteks ini, machine learning dipandang sebagai metode analisis yang unggul karena kemampuannya dalam mempelajari pola hubungan antar variabel medis secara otomatis tanpa bergantung pada interpretasi manual tenaga medis. Melalui

pendekatan ini, komputer dapat belajar dari data historis pasien dan membangun model prediktif yang mampu mengidentifikasi jenis diabetes dengan akurasi tinggi.

Kerangka berpikir penelitian ini berawal dari kesadaran akan keterbatasan metode klasifikasi konvensional yang masih banyak bergantung pada hasil laboratorium dan analisis subjektif. Dalam praktik klinis, proses identifikasi jenis diabetes sering kali memerlukan waktu yang lama dan berpotensi menghasilkan perbedaan diagnosis antar tenaga medis. Kondisi ini menimbulkan kebutuhan terhadap sistem pendukung keputusan yang dapat bekerja secara objektif, cepat, dan efisien. Dari permasalahan tersebut, muncul gagasan untuk menerapkan machine learning sebagai alternatif inovatif dalam klasifikasi penyakit diabetes.

Dalam penelitian ini, data yang digunakan berupa data sekunder yang mencakup parameter-parameter klinis seperti kadar glukosa darah, tekanan darah, indeks massa tubuh (BMI), kadar insulin, dan usia pasien. Variabel-variabel tersebut diolah dan dianalisis menggunakan algoritma machine learning untuk mendeteksi pola yang berkaitan dengan jenis diabetes. Fokus penelitian diarahkan pada penerapan pendekatan *multi-class*, yaitu 0= *non diabetic*, 1= *diabetic*, 2= *predict diabetic*. Pendekatan ini lebih kompleks dibandingkan klasifikasi biner karena melibatkan pembelajaran pola yang lebih variatif dan hubungan antar variabel yang lebih dinamis.

Proses berpikir dalam penelitian ini berlangsung secara sistematis. Tahapan pertama dimulai dengan identifikasi masalah, yaitu adanya ketidakefisienan dan subjektivitas dalam sistem klasifikasi diabetes konvensional. Setelah itu, dilakukan kajian teoritis untuk memahami konsep dasar machine learning dan potensi penerapannya di bidang medis, khususnya dalam diagnosis penyakit kronis seperti diabetes. Berdasarkan kajian literatur, machine learning telah terbukti mampu mengenali pola data medis secara efektif, tetapi sebagian besar penelitian sebelumnya masih terbatas pada klasifikasi dua kategori.

Langkah berikutnya adalah merancang solusi dengan menerapkan beberapa algoritma machine learning seperti *SVM (Support Vector Machine)*, *RF (Random*

Forest), *DT (Decision Tree)*, *LR (Logistic Regression)* (Fahrurrozi et al., 2025). Masing-masing algoritma memiliki keunggulan dalam hal pengolahan data non-linear, kemampuan generalisasi, dan akurasi prediksi. Data yang diperoleh kemudian melalui tahapan preprocessing, meliputi pembersihan data, normalisasi, serta seleksi fitur yang relevan untuk menghindari redundansi informasi. Selanjutnya dilakukan proses pelatihan (*training*) model dengan menggunakan *dataset* yang telah dilabeli berdasarkan tipe diabetes, kemudian dilakukan pengujian (*testing*) untuk mengukur performa model dalam mengklasifikasikan data baru.

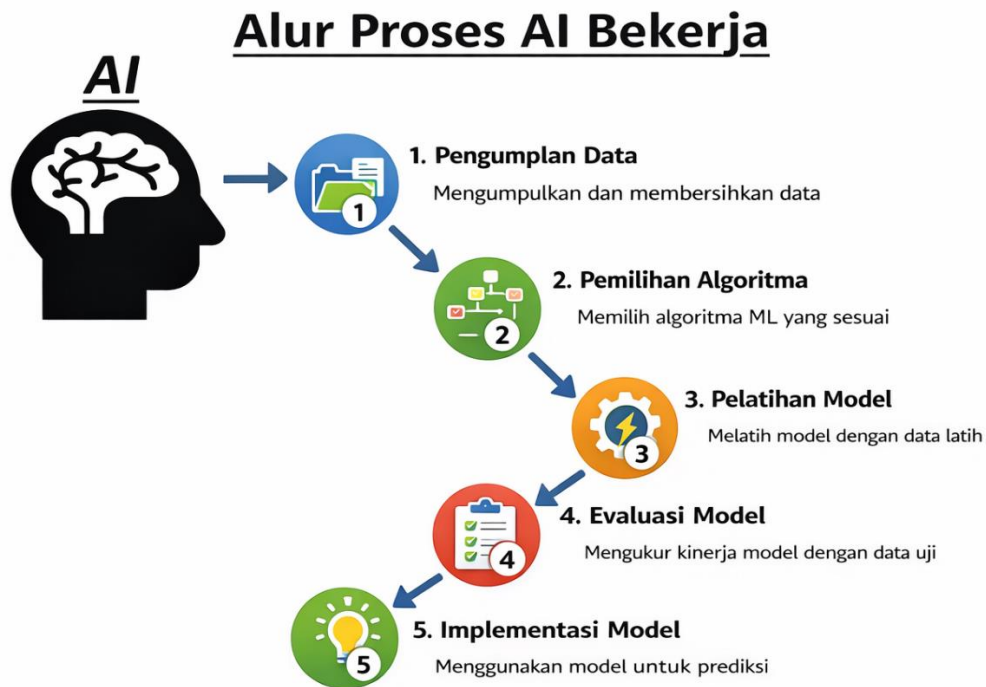
Hasil dari proses klasifikasi dianalisis secara kualitatif untuk memahami pola yang terbentuk dari hubungan antara variabel input dan tipe diabetes yang dihasilkan model (CINDI, 2024). Analisis ini tidak hanya menilai tingkat akurasi, tetapi juga meninjau keterkaitan logis antara hasil klasifikasi dengan kondisi klinis yang sebenarnya. Melalui pendekatan kualitatif, peneliti dapat menggali lebih dalam bagaimana algoritma mengenali pola data dan sejauh mana hasil klasifikasi tersebut dapat diinterpretasikan secara medis.

Pada akhirnya, penelitian ini diharapkan dapat menghasilkan model *machine learning* yang mampu mengklasifikasikan jenis diabetes dengan lebih akurat dan komprehensif dibandingkan metode manual. Selain itu, hasil penelitian juga diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan medis berbasis teknologi elektro, yang dapat diterapkan dalam perangkat atau sistem cerdas di fasilitas kesehatan. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoretis dalam pengembangan teknologi klasifikasi berbasis *machine learning*, tetapi juga memiliki nilai praktis dalam meningkatkan efisiensi dan akurasi diagnosis penyakit diabetes di masa depan.

BAB II TINJAUAN PUSTAKA

2.1. Kecerdasan Buatan (*Artificial Intelligence*)

Kecerdasan Buatan atau *Artificial Intelligence* (AI) merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem atau mesin yang mampu meniru kemampuan berpikir dan pengambilan keputusan layaknya manusia (Manalu, 2024). AI tidak hanya berorientasi pada kemampuan komputasi, tetapi juga mencakup proses pembelajaran, penalaran, persepsi, serta kemampuan untuk beradaptasi terhadap kondisi baru.



Gambar 1. Alur Proses Artificial Intelligence (AI) Bekerja

Artificial Intelligence (AI) atau yang dalam Bahasa Indonesia dapat diartikan Kecerdasan buatan, adalah teknologi yang memungkinkan sistem computer untuk meniru fungsi kognitif manusia, seperti belajar, memecahkan masalah, memahami Bahasa, dan mengambil Keputusan, dimana dalam prosesnya AI ini menggunakan

data dalam jumlah besar untuk menjalankan tugas-tugas yang biasanya membutuhkan kecerdasan manusia, dalam memproses informasi dengan cepat dan beradaptasi dengan situasi baru untuk meningkatkan efisiensi dan membantu pemecahan masalah yang kompleks. Dalam pengaplikasinya AI tidak dapat beroperasi secara mandiri (Suhardi et al., 2024). Diperlukan *Machine learning* untuk dapat menjalankan dan mengoperasikan serta mengolah data dalam jumlah besar.

Gambar tersebut menjelaskan alur proses kerja *Artificial Intelligence* (AI) secara sistematis mulai dari tahap pengumpulan data hingga implementasi model. Proses diawali dengan pengumpulan data, di mana sistem AI memerlukan data dalam jumlah besar sebagai “bahan bakar” pembelajaran. Data yang digunakan bisa berupa teks, gambar, suara, maupun data numerik lainnya. Setelah data terkumpul, dilakukan pembersihan dan pra-pemrosesan untuk menghapus data yang tidak relevan, memperbaiki kesalahan, serta menyiapkan format agar dapat digunakan dalam pelatihan model.

Tahap berikutnya adalah pemilihan algoritma, di mana berbagai algoritma machine learning digunakan untuk menemukan pola dan hubungan antarvariabel dalam data. Setelah algoritma ditentukan, dilakukan pelatihan model menggunakan data yang telah diproses. Pada tahap ini, sistem AI “belajar” dari data untuk mengenali pola-pola tersembunyi.

Selanjutnya, model yang telah dilatih akan melewati tahap evaluasi untuk menilai sejauh mana akurasi dan performanya dalam mengenali pola atau memprediksi hasil. Bila hasil evaluasi belum optimal, dilakukan penyempurnaan dengan menyesuaikan parameter atau memperbaiki kualitas data agar model menjadi lebih akurat. Tahap terakhir adalah implementasi dan penerapan model, di mana model yang sudah matang digunakan dalam aplikasi nyata, seperti sistem prediksi, klasifikasi, atau pengambilan keputusan otomatis.

Konsep di atas menggambarkan bahwa proses kerja AI merupakan siklus berkelanjutan yang tidak berhenti setelah model diterapkan. AI terus diperbarui dan disempurnakan seiring bertambahnya data dan kebutuhan, sehingga menghasilkan

sistem yang semakin cerdas dan adaptif terhadap perubahan lingkungan maupun konteks penggunaannya.

AI dapat didefinisikan sebagai sistem yang dirancang untuk bertindak secara rasional dalam mencapai tujuan tertentu melalui analisis lingkungan dan pemilihan tindakan yang optimal. Dalam konteks modern, AI tidak lagi hanya terbatas pada teori, tetapi telah menjadi bagian dari berbagai bidang terapan, seperti pengenalan citra (*image recognition*), analisis data medis, sistem rekomendasi, dan kendaraan otonom.

Artificial Intelligence (AI) atau kecerdasan buatan merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang mampu meniru kemampuan berpikir, belajar, dan mengambil keputusan layaknya manusia. Secara konseptual, AI dapat didefinisikan sebagai sistem yang dirancang untuk bertindak secara rasional dalam mencapai tujuan tertentu dengan cara menganalisis lingkungan, memproses informasi, dan memilih tindakan yang paling optimal berdasarkan hasil analisis tersebut. Dalam praktiknya, AI berupaya menciptakan entitas digital yang tidak hanya mampu memproses data secara cepat, tetapi juga mampu memahami konteks, mengenali pola, serta melakukan adaptasi terhadap perubahan kondisi di sekitarnya.

Dalam konteks perkembangan teknologi modern, penerapan AI telah meluas ke berbagai bidang kehidupan dan industri (Mahendra et al., 2024). Pada bidang kesehatan, misalnya, AI digunakan untuk menganalisis citra medis seperti *MRI* dan *CT scan*, membantu diagnosis penyakit, serta memprediksi risiko kesehatan berdasarkan data rekam medis pasien. Di sektor keuangan, AI dimanfaatkan untuk mendeteksi potensi penipuan transaksi, melakukan analisis risiko investasi, hingga mengoptimalkan strategi perdagangan saham melalui algoritma otomatis. Sementara itu, dalam bidang transportasi, teknologi AI menjadi fondasi bagi pengembangan kendaraan otonom yang mampu mengemudi sendiri dengan memanfaatkan sensor dan sistem pembelajaran lingkungan.

Selain itu, AI juga banyak digunakan dalam sistem rekomendasi, seperti yang ditemukan di *platform e-commerce* atau layanan *streaming*, di mana algoritma AI menganalisis perilaku pengguna untuk memberikan saran produk atau konten yang relevan. Di bidang pendidikan, AI membantu proses pembelajaran adaptif dengan menyesuaikan materi berdasarkan kemampuan dan progres masing-masing siswa.

Dengan kemampuan untuk memproses data dalam jumlah besar dan menemukan pola kompleks yang sulit diidentifikasi oleh manusia, AI menjadi salah satu teknologi paling revolusioner dalam era digital. Namun, penting untuk dipahami bahwa AI tidak hanya berfungsi sebagai alat otomatisasi, tetapi juga sebagai sistem pembelajaran berkelanjutan yang terus meningkatkan kemampuannya seiring bertambahnya pengalaman dan data. Hal ini menjadikan AI bukan sekadar teknologi statis, melainkan entitas dinamis yang berperan besar dalam mendukung pengambilan keputusan berbasis data, efisiensi operasional, dan inovasi di berbagai bidang kehidupan modern.

Perkembangan AI juga didorong oleh kemajuan teknologi komputasi dan ketersediaan data dalam jumlah besar (*big data*) (Zaenudin & Riyan, 2024). Melalui kemampuan ini, AI dapat digunakan untuk menganalisis data kompleks dan mengidentifikasi pola yang sulit ditemukan oleh manusia. Di bidang kesehatan, AI berperan penting dalam mendukung diagnosis penyakit, prediksi risiko, serta pengembangan sistem pendukung keputusan medis yang lebih efisien dan akurat.

Perkembangan *Artificial Intelligence* (AI) dalam satu dekade terakhir tidak dapat dilepaskan dari kemajuan pesat di bidang teknologi komputasi dan meningkatnya ketersediaan data dalam skala besar, yang dikenal sebagai *big data*. Kombinasi antara daya komputasi tinggi, algoritma pembelajaran yang semakin canggih, serta akses terhadap data dalam jumlah masif menjadi katalis utama dalam mempercepat inovasi di bidang kecerdasan buatan. *Big data* menyediakan “bahan bakar” bagi sistem AI untuk belajar dari berbagai jenis informasi, baik berupa data numerik, teks, citra, suara, maupun sinyal biologis. Semakin banyak dan beragam

data yang dianalisis, semakin baik pula kemampuan AI dalam mengenali pola dan menghasilkan prediksi yang akurat.

Salah satu kekuatan utama AI adalah kemampuannya dalam menganalisis data kompleks dan multidimensional yang sulit dipahami oleh manusia dalam waktu singkat. AI mampu memproses jutaan data dalam hitungan detik, mengidentifikasi keterkaitan tersembunyi antarvariabel, dan menghasilkan wawasan yang sebelumnya tidak dapat ditemukan melalui metode analisis konvensional. Proses ini menjadi sangat bermanfaat dalam bidang-bidang yang melibatkan data besar dan kompleks, seperti kesehatan, finansial, transportasi, hingga pendidikan.

Dalam dunia kesehatan, AI memiliki peran strategis dan semakin tidak tergantikan. Teknologi ini telah digunakan dalam berbagai aplikasi medis, mulai dari diagnosis penyakit, prediksi risiko kesehatan, hingga pengembangan sistem pendukung keputusan medis (*Clinical Decision Support Systems/CDSS*) (Marlina, 2025).

Misalnya, algoritma berbasis *machine learning* dapat dilatih untuk mengenali pola-pola tertentu dalam data medis pasien, seperti hasil tes laboratorium, citra radiologi, atau riwayat rekam medis elektronik (*Electronic Health Record*). Dengan analisis tersebut, AI mampu membantu tenaga medis dalam mengidentifikasi kemungkinan penyakit sejak dini, memperkirakan tingkat keparahan kondisi, dan bahkan merekomendasikan langkah perawatan yang paling sesuai.

Selain meningkatkan akurasi diagnosis, penerapan AI dalam bidang kesehatan juga berkontribusi terhadap efisiensi waktu dan sumber daya. Proses analisis yang biasanya membutuhkan waktu berjam-jam atau bahkan berhari-hari dapat diselesaikan dalam hitungan menit. AI juga dapat meminimalkan potensi bias manusia dalam pengambilan keputusan medis dengan menyediakan hasil berbasis data dan probabilitas. Hal ini sangat penting dalam kasus penyakit kronis seperti diabetes melitus, di mana penentuan tipe penyakit dan penyesuaian terapi membutuhkan analisis mendalam terhadap banyak faktor klinis.

Dengan demikian, perkembangan AI yang didukung oleh kemajuan komputasi dan big data tidak hanya mendorong efisiensi dalam pengolahan informasi, tetapi juga membuka peluang besar bagi inovasi medis yang lebih personal, presisi, dan adaptif terhadap kondisi pasien. Teknologi ini bukan lagi sekadar alat bantu, tetapi telah menjadi bagian integral dalam ekosistem kesehatan modern yang berorientasi pada kecepatan, ketepatan, dan berbasis data ilmiah.

2.2. Machine Learning

Machine Learning merupakan salah satu cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang memungkinkan komputer untuk belajar dari data tanpa harus diprogram secara eksplisit (Rojabi, 2025). Secara sederhana, *machine learning* membuat sistem dapat mengenali pola dari data historis dan kemudian menggunakannya untuk membuat prediksi atau keputusan pada data baru.

Dalam penerapannya, *machine learning* bekerja melalui beberapa tahapan yang dimulai dari pengumpulan data, pembersihan data (*data preprocessing*), pemilihan algoritma, pelatihan model, evaluasi hasil, hingga penerapan model ke dunia nyata. Data yang digunakan dapat berupa teks, angka, citra, maupun sinyal sensor, tergantung pada kebutuhan dan konteks penelitian.

Proses pelatihan model dilakukan menggunakan berbagai algoritma populer seperti *SVM (Support Vector Machine)*, *RF (Random Forest)*, *DT (Decision Tree)*, *LR (Logistic Regression)* (Fahrurrozi et al., 2025). Melalui proses ini, model *machine learning* berupaya memahami hubungan antarvariabel di dalam data dan membentuk pola yang dapat digunakan untuk memprediksi hasil baru secara akurat.

Machine learning sendiri dibagi menjadi tiga pendekatan utama, yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning*. Pada *supervised learning*, model dilatih menggunakan data yang telah memiliki label, seperti dalam kasus klasifikasi pasien menjadi *multi-class*, yaitu 0= *non diabetic*, 1= *diabetic*, 2= *predict diabetic*. Sementara itu, *unsupervised learning* digunakan

untuk menemukan pola tersembunyi atau pengelompokan alami dalam data tanpa adanya label, misalnya dalam mengelompokkan pasien berdasarkan kesamaan gejala. Adapun *reinforcement learning* berfokus pada proses pembelajaran berbasis pengalaman, di mana sistem belajar dari umpan balik berupa penghargaan (*reward*) atau hukuman (*punishment*) untuk menentukan strategi terbaik dalam mencapai tujuan tertentu.

Dalam dunia nyata, penerapan machine learning telah memberikan kontribusi signifikan di berbagai bidang. Di sektor kesehatan, *machine learning* digunakan untuk mendeteksi penyakit berdasarkan hasil laboratorium, menganalisis citra medis seperti *MRI* atau *CT scan*, serta memprediksi komplikasi berdasarkan data pasien. Di sektor keuangan, teknologi ini membantu mendeteksi aktivitas penipuan dan memprediksi *trend* pasar. Sedangkan dalam teknologi informasi, *machine learning* menjadi fondasi sistem rekomendasi, pengenalan suara, serta analisis perilaku pengguna di berbagai platform digital.

Keunggulan utama dari *machine learning* terletak pada kemampuannya untuk berkembang secara adaptif dan dinamis (Sultan et al., 2025). Semakin banyak data yang digunakan, semakin akurat model yang dihasilkan, karena algoritma dapat terus memperbarui pemahamannya terhadap pola dan hubungan antarvariabel. Namun, kualitas data tetap menjadi faktor yang sangat penting. Model yang dilatih menggunakan data yang tidak bersih, bias, atau tidak representatif dapat menghasilkan keputusan yang keliru. Oleh karena itu, keberhasilan penerapan machine learning tidak hanya bergantung pada kecanggihan algoritma, tetapi juga pada ketelitian dalam pemrosesan data dan evaluasi performa model.

Machine learning berperan besar dalam mendukung proses analisis berbasis data dan pengambilan keputusan otomatis. Dalam konteks penelitian medis, termasuk dalam klasifikasi penyakit diabetes melitus, penerapan *machine learning* memberikan peluang besar untuk meningkatkan ketepatan diagnosis, mempercepat analisis, dan membantu tenaga medis mengambil keputusan berbasis data ilmiah yang lebih akurat dan efisien.

2.3. Peralatan Kerja yang Digunakan

Dalam penelitian ini, perangkat utama yang digunakan adalah laptop sebagai alat komputasi dan analisis data. Laptop dipilih karena memiliki fleksibilitas tinggi, efisiensi energi, dan kemampuan untuk menjalankan perangkat lunak analisis data (Yulianti, 2023).

Laptop juga menjadi pilihan ideal karena mampu mendukung berbagai platform dan perangkat lunak analisis data yang digunakan dalam penelitian ini. Beberapa aplikasi utama yang dimanfaatkan antara lain *Python*, *Jupyter Notebook*, dan *Google Colab* (Octarina et al., 2025). Bahasa pemrograman *Python* dipilih karena bersifat *open-source*, mudah digunakan, serta memiliki komunitas pengguna yang luas di bidang *data science* dan *machine learning*. Melalui *Python*, peneliti dapat dengan mudah mengimplementasikan berbagai algoritma klasifikasi dan melakukan evaluasi performa model dengan tingkat fleksibilitas yang tinggi.

Selain itu, *Jupyter Notebook* digunakan sebagai lingkungan kerja interaktif yang memungkinkan peneliti untuk menulis kode, menampilkan hasil analisis, dan membuat dokumentasi secara bersamaan dalam satu antarmuka. Hal ini mempermudah proses eksplorasi data dan penyusunan laporan hasil analisis. Sementara itu, *Google Colab* dimanfaatkan sebagai alternatif berbasis *cloud* yang menawarkan sumber daya komputasi tambahan.

Pemanfaatan laptop dengan spesifikasi yang memadai memungkinkan seluruh tahapan penelitian, mulai dari pengumpulan data, pra-pemrosesan, pelatihan model, evaluasi hasil, hingga visualisasi data, dapat dilakukan secara efisien tanpa hambatan teknis yang signifikan. Selain itu, dengan dukungan berbagai perangkat lunak dan pustaka tersebut, peneliti dapat menjalankan eksperimen secara berulang dan melakukan perbandingan antar-algoritma dengan lebih mudah.

Dengan demikian, penggunaan laptop dalam penelitian ini bukan sekadar sebagai alat bantu analisis, tetapi juga berfungsi sebagai pusat integrasi seluruh aktivitas komputasi, mulai dari pemrograman, simulasi, hingga pelaporan hasil

penelitian. Fleksibilitas dan kompatibilitas yang ditawarkan perangkat ini menjadikannya pilihan yang tepat untuk penelitian berbasis *machine learning* di bidang teknik elektro, khususnya dalam penerapan klasifikasi penyakit diabetes yang memerlukan kombinasi antara kemampuan komputasi dan analisis data berbasis kecerdasan buatan.

Laptop dalam penelitian ini berfungsi sebagai media utama untuk melakukan data preprocessing, pelatihan model (*training*), pengujian model (*testing*), serta visualisasi hasil analisis. Dengan menggunakan perangkat ini, seluruh proses penelitian dapat dilakukan secara mandiri dan efisien tanpa memerlukan perangkat keras tambahan.

Secara keseluruhan, penggunaan laptop dalam penelitian ini tidak hanya sebagai perangkat komputasi, tetapi juga sebagai *platform* integratif yang menggabungkan berbagai aktivitas analisis data, pengujian algoritma, dan pelaporan hasil penelitian. Kombinasi antara kemampuan teknis laptop dan dukungan perangkat lunak analisis modern menjadikannya alat yang ideal untuk penelitian berbasis *machine learning*, terutama dalam konteks klasifikasi multi-tipe penyakit diabetes yang membutuhkan kecepatan, ketepatan, serta keandalan dalam pemrosesan data dan pelatihan model.

2.4. Pengertian Penyakit Diabetes

Diabetes merupakan penyakit metabolik kronis yang ditandai dengan peningkatan kadar glukosa darah akibat gangguan pada produksi atau kerja insulin. Diabetes terjadi ketika tubuh tidak dapat menghasilkan insulin dalam jumlah yang cukup atau tidak dapat menggunakan insulin secara efektif (Putri, 2025). Insulin sendiri merupakan hormon yang dihasilkan oleh pankreas dan berfungsi untuk mengatur kadar gula dalam darah agar tetap stabil.

Perkembangan teknologi modern, terutama dalam bidang *artificial intelligence* (AI) dan *machine learning* (Manalu, 2024) telah membuka peluang baru dalam memahami dan menangani penyakit diabetes. Teknologi ini memungkinkan

analisis data medis secara lebih cepat, akurat, dan berbasis pola, sehingga dapat membantu dalam proses diagnosis dan prediksi risiko penyakit. Dengan memanfaatkan data klinis pasien seperti kadar glukosa, tekanan darah, indeks massa tubuh, dan riwayat keluarga, model *machine learning* mampu mengidentifikasi pola-pola tersembunyi yang sulit dideteksi secara manual oleh tenaga medis.

Dampak sosial dan ekonomi dari diabetes juga sangat besar. Biaya pengobatan dan perawatan komplikasi diabetes dapat membebani sistem kesehatan negara, terutama di negara berkembang seperti Indonesia. Selain itu, penurunan produktivitas akibat komplikasi kronis juga berdampak pada kualitas hidup penderita dan keluarganya. Oleh karena itu, berbagai upaya pencegahan dan penanganan berbasis teknologi mulai dikembangkan untuk membantu proses diagnosis dan prediksi risiko penyakit ini. Salah satunya adalah penerapan *machine learning* yang mampu menganalisis data medis pasien dan mengidentifikasi pola-pola penting untuk mendukung pengambilan keputusan medis yang lebih akurat.

Dengan demikian, diabetes melitus bukan hanya sekadar penyakit kronis yang berkaitan dengan kadar gula darah, tetapi juga masalah kesehatan global yang memiliki implikasi multidimensi. Pendekatan komprehensif yang melibatkan pencegahan, deteksi dini, serta pengelolaan berkelanjutan untuk menekan angka kejadian dan dampak komplikasi penyakit ini (Marlim et al., 2022). Peran teknologi seperti kecerdasan buatan dan data-driven healthcare menjadi sangat penting dalam mewujudkan sistem kesehatan yang lebih adaptif dan berbasis bukti ilmiah di era digital saat ini.

2.5. Feature Kategori Penyakit Diabetes

Dalam konteks penelitian berbasis *machine learning* (Maulani et al., 2025) istilah *feature* mengacu pada atribut atau variabel yang digunakan untuk menggambarkan karakteristik data yang akan dianalisis. *Feature* berfungsi sebagai input utama yang digunakan oleh algoritma *machine learning* untuk mempelajari

pola dan membuat prediksi. Dalam penelitian mengenai klasifikasi penyakit diabetes melitus, pemilihan *feature* yang tepat menjadi aspek yang sangat penting.

Dalam penelitian tentang klasifikasi penyakit diabetes melitus, pemilihan dan pengolahan *feature* menjadi tahapan yang krusial karena kualitas data yang digunakan akan sangat menentukan performa model. *Feature* yang baik harus relevan, informatif, dan mampu merepresentasikan kondisi fisiologis pasien secara menyeluruh. Setiap variabel yang digunakan sebagai *feature* memiliki nilai diagnostik tertentu yang dapat mencerminkan adanya ketidakseimbangan metabolik dalam tubuh. Karena diabetes merupakan penyakit yang kompleks dan melibatkan berbagai mekanisme biologis, maka pemilihan *feature* tidak bisa dilakukan secara sembarangan harus didasarkan pada pemahaman medis yang kuat mengenai proses terjadinya penyakit tersebut.

Feature dalam penelitian klasifikasi diabetes bukan sekadar kumpulan angka, tetapi representasi digital dari kondisi fisiologis manusia yang dikonversi menjadi bentuk yang dapat dipahami oleh sistem komputer. Pemilihan dan pengolahan *feature* yang tepat akan menghasilkan model *machine learning* yang mampu mengklasifikasikan tipe diabetes secara akurat, membantu proses diagnosis dini, serta mendukung pengambilan keputusan medis berbasis data. Pendekatan ini tidak hanya memberikan manfaat dalam konteks akademis, tetapi juga memiliki potensi besar dalam implementasi sistem kesehatan digital yang lebih cerdas dan efisien di masa depan.

Penting untuk dipahami bahwa tidak semua *feature* memiliki pengaruh yang sama terhadap hasil klasifikasi. Beberapa algoritma *machine learning* mampu menilai tingkat kepentingan dari masing-masing variabel, sehingga peneliti dapat mengetahui fitur mana yang paling menentukan dalam proses klasifikasi. Informasi ini tidak hanya berguna untuk meningkatkan kinerja model, tetapi juga memberikan wawasan medis yang lebih mendalam mengenai faktor-faktor yang paling memengaruhi timbulnya diabetes.

Dengan demikian, *feature* kategori penyakit diabetes memiliki peran yang sangat vital dalam membangun model klasifikasi yang akurat dan reliabel. Pemilihan variabel yang tepat, didukung oleh pemahaman ilmiah yang kuat tentang hubungan antara faktor klinis dan metabolik, akan membantu sistem *machine learning* dalam menghasilkan model prediksi yang efektif. Pendekatan ini diharapkan dapat mendukung proses diagnosis dini, meminimalkan kesalahan klasifikasi, serta memberikan dasar ilmiah bagi pengembangan sistem pendukung keputusan medis yang lebih cerdas dan adaptif terhadap kebutuhan pasien.

BAB III METODOLOGI PENELITIAN

3.1. Waktu Penelitian

Penelitian ini menggunakan pendekatan kualitatif deskriptif (Moleong, 1990) dengan dukungan analisis berbasis *machine learning*. Pendekatan ini dipilih karena fokus penelitian bukan hanya untuk menghasilkan model prediktif, tetapi juga untuk memahami secara mendalam bagaimana algoritma *machine learning* mampu mengidentifikasi pola dan karakteristik yang membedakan setiap kategori penyakit diabetes. Pendekatan kualitatif digunakan untuk menjelaskan proses analisis, pemilihan algoritma, interpretasi hasil, serta pengaruh setiap feature terhadap proses klasifikasi.

Selain itu, penelitian ini juga memiliki elemen eksperimen terapan (*applied research*) (Dwi Joko et al., n.d.) di mana model *machine learning* dikembangkan menggunakan dataset publik yang tersedia secara daring. Melalui pendekatan ini, peneliti dapat mengamati performa model pada data nyata serta menilai efektivitas berbagai algoritma dalam konteks klasifikasi multikategori penyakit diabetes.

3.2. Sumber Data

Data yang digunakan dalam penelitian ini berasal dari situs Kaggle dengan judul proyek “*Multiclass Diabetes Classification (ML Accuracy: 98.11%)*” yang dikembangkan oleh Sonawane Lalit Sunil. Dataset ini bersifat publik dan *open-source*, sehingga dapat digunakan untuk tujuan penelitian dan pengembangan model *machine learning* dengan *Web Kaggle* yang data klasifikasinya 0= *non diabetic*, 1= *diabetic*, 2= *predict diabetic*.

Setiap entri data memuat sejumlah *feature* klinis yang relevan untuk analisis, antara lain:

1. *Age* (usia pasien)
2. *BMI (Body Mass Index)*
3. *Blood Pressure* (tekanan darah)

4. *Glucose Level* (kadar glukosa darah)
5. *Insulin Level*
6. *Pregnancies* (jumlah kehamilan, untuk pasien perempuan)
7. *Skin Thickness*
8. *Diabetes Pedigree Function* (indikator riwayat keluarga)

3.4. Metode Pengumpulan Data

Karena penelitian ini berbasis data sekunder, maka teknik pengumpulan data dilakukan melalui akses daring (*online data retrieval*) dari *platform Kaggle*. Dataset kemudian diunduh dalam format CSV (*Comma Separated Values*) untuk selanjutnya diolah menggunakan bahasa pemrograman *Python*.

Proses pengumpulan data meliputi beberapa tahapan berikut:

1. Mengunduh dataset dari tautan Kaggle yang telah disebutkan.
2. Melakukan pengecekan kelengkapan dan validitas data menggunakan *Python Library Pandas*.
3. Membersihkan data dari nilai kosong (*missing values*) dan data duplikat.
4. Melakukan normalisasi nilai numerik agar berada dalam rentang yang seragam sehingga tidak menyebabkan bias pada model.
5. Setelah data siap, tahap selanjutnya adalah eksplorasi untuk memahami sebaran dan hubungan antar-variabel.

3.5. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahap sistematis yang saling berkaitan. Tahapan tersebut dapat dijelaskan sebagai berikut:

1. Studi Literatur

Pada tahap awal, peneliti melakukan kajian pustaka terhadap berbagai referensi terkait *machine learning*, algoritma klasifikasi, serta penelitian terdahulu yang relevan dengan topik multi-klasifikasi penyakit diabetes. Tujuannya adalah untuk memperoleh landasan teori yang kuat sebagai dasar dalam merancang model dan menganalisis hasil penelitian.

2. Tahap Persiapan Data (Data Preparation)

- a. Pengumpulan Dataset: Mengambil data dari *Multiclass Diabetes Dataset* (file CSV).
- b. Data Pre-processing: Melakukan pembersihan data, penanganan data yang hilang (*missing values*), dan transformasi label kategori menjadi data numerik menggunakan Label Encoder dengan pembagian *multi-class* sebagai berikut: **0 = Non-Diabetic** (Pasien sehat / tidak diabetes); **1 = Diabetic** (Pasien penderita diabetes); dan **2 = Predict Diabetic** (Pasien dengan prediksi prediabetes / fase transisi).

3. Tahap Pengembangan Model

- a. Data Splitting: Membagi dataset menjadi 80% data latih (*training set*) dan 20% data uji (*testing set*).
- b. Implementasi Algoritma: Melatih empat model algoritma *machine learning*, yaitu:
 - 1) SVM (*Support Vector Machine*)
 - 2) RF (*Random Forest*)
 - 3) DT (*Decision Tree*)
 - 4) LR (*Logistic Regression*)

4. Evaluasi dan Analisis Hasil

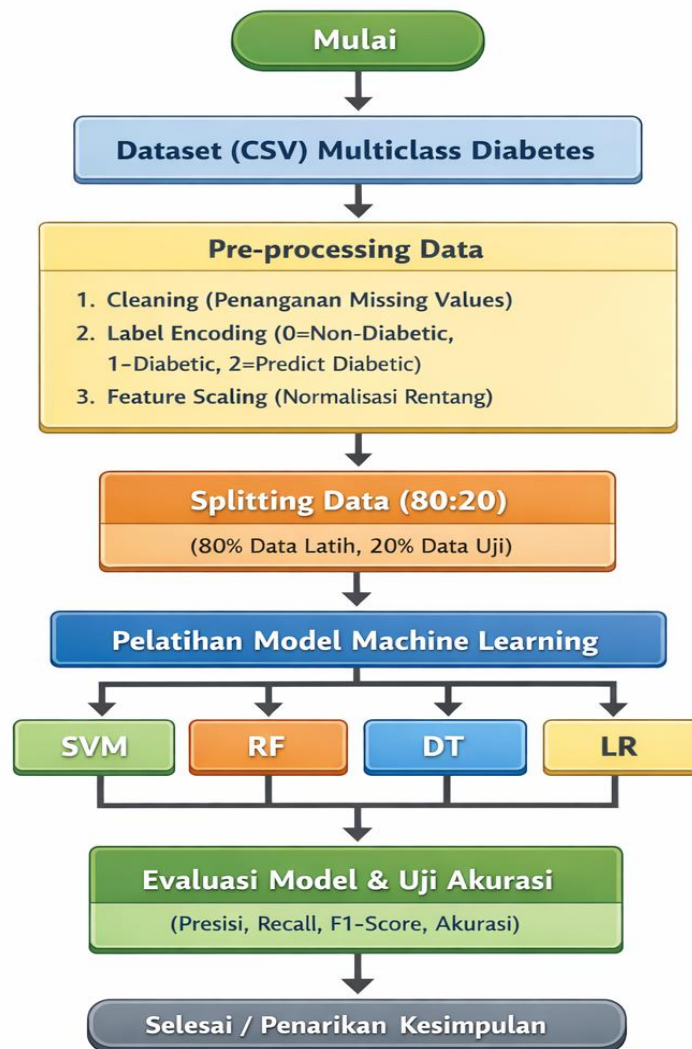
Setelah model diuji, hasil akurasi dari masing-masing algoritma dibandingkan untuk menentukan model terbaik. Analisis dilakukan secara kualitatif untuk menilai faktor yang menyebabkan perbedaan performa, serta menjelaskan interpretasi hasil dari sisi medis dan teknis.

3.6. Teknik Analisis Data

Analisis data dalam penelitian ini dilakukan melalui dua pendekatan, yaitu analisis kuantitatif berbasis model ML dan analisis kualitatif deskriptif (Sugiyono, 2013). Analisis kuantitatif dilakukan dengan mengevaluasi hasil akurasi model

serta metrik performa lainnya seperti *precision*, *recall*, dan *F1-score*. Sementara itu, analisis kualitatif digunakan untuk menjelaskan interpretasi hasil secara mendalam misalnya bagaimana pola tertentu pada kadar glukosa, tekanan darah, atau BMI dapat memengaruhi hasil klasifikasi. Dengan demikian, hasil penelitian tidak hanya bersifat numerik, tetapi juga memberikan pemahaman yang bermakna terhadap faktor medis yang memengaruhi munculnya diabetes pada berbagai kategori.

3.7. Diagram Alur Penelitian (Flowchart)



Gambar 2. Alur Penelitian

Diagram alir berikut menggambarkan urutan logis dari penelitian yang dilakukan:

Pelaksanaan penelitian ini mengikuti urutan logis yang terstruktur untuk membangun model multi-klasifikasi penyakit diabetes. Tahapan penelitian diawali dengan penentuan parameter input pada fase **mulai**. Selanjutnya, tahapan pengumpulan data dilakukan dengan memuat **dataset (CSV)** yang berisi rekam data medis pasien. Data ini mencakup variabel-variabel prediktor yang krusial, seperti tingkat HbA1c, *Body Mass Index* (BMI), kadar glukosa, urea, serta kreatinin.

Setelah data terkumpul, tahapan krusial berikutnya adalah **pre-processing data** guna memastikan kualitas data sebelum dimasukkan ke dalam model. Proses ini terbagi menjadi tiga langkah utama: pertama, proses *cleaning* untuk membersihkan dataset dan memastikan tidak ada data yang kosong (*missing values*); kedua, *label encoding* yang berfungsi untuk mentransformasikan kategori kelas target (Non-Diabetes, Diabetes, dan Prediabetes) menjadi representasi numerik secara berurutan, yaitu 0, 1, dan 2; dan ketiga, proses *scaling* untuk menormalisasi nilai data sehingga seluruh fitur memiliki rentang yang seragam dan proporsional (misalnya direntangkan dalam skala 0 hingga 1).

Data yang telah dibersihkan dan dinormalisasi kemudian masuk ke tahap pembagian atau **splitting data**. Pada penelitian ini, dataset dipisahkan menggunakan rasio 80:20, di mana 80% dari total data dialokasikan untuk proses pelatihan model, sedangkan 20% sisanya disimpan murni sebagai data pengujian. Tahap inti berikutnya adalah **pelatihan model (training)**, yang melibatkan proses pencocokan (*fitting*) data latih ke dalam empat algoritma *machine learning*, yaitu *Random Forest* (RF), *Decision Tree* (DT), *Support Vector Machine* (SVM), dan *Logistic Regression* (LR).

Untuk mengukur sejauh mana keandalan model yang telah dilatih, tahapan **uji akurasi dan metrik** dilakukan menggunakan data pengujian. Evaluasi hasil prediksi ini secara komprehensif dianalisis menggunakan *Confusion Matrix* untuk

mendapatkan nilai performa metrik lanjutan, seperti *Precision* (presisi), *Recall*, dan *F1-Score*. Pada tahap akhir (**selesai**), seluruh hasil pengujian dievaluasi untuk melakukan penarikan kesimpulan yang objektif mengenai algoritma atau metode mana yang memberikan performa terbaik dalam mengklasifikasikan risiko penyakit diabetes.

3.8. Jadwal Penelitian

Sebagai bagian dari rencana, berikut adalah estimasi waktu pelaksanaan penelitian:

Tabel 1. Jadwal Penelitian

No	Tahapan Penelitian	Agustus 2025 s.d Januari 2026					
		Agst	Sep	Okt	Nov	Des	Jan
1	Studi Literatur & Identifikasi Masalah	√					
2	Pengumpulan & Pre-processing Data		√	√			
3	Training Model & Cross Validation			√	√		
4	Evaluasi, Analisis Hasil & Penyusunan Laporan					√	√

BAB IV

HASIL DAN PEMBAHASAN

4.1. Hasil Uji Klasifikasi Model *Machine Learning*

Pada tahap ini, dilakukan evaluasi terhadap empat model algoritma *machine learning* yang digunakan untuk mengklasifikasikan penyakit diabetes. Evaluasi model didasarkan pada matriks kebingungan (*confusion matrix*) dan laporan klasifikasi yang mencakup nilai *Precision*, *Recall*, *F1-Score*, dan Akurasi. Data uji yang digunakan bersumber dari dataset sekunder yang telah dibagi (*data splitting*) melalui proses yang dijelaskan pada tahapan penelitian.

```
In [0]: #! IMPORT ALL LIBRARY
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split, cross_val_score, GridSearchCV
from sklearn.preprocessing import StandardScaler, LabelEncoder
from sklearn.metrics import classification_report, confusion_matrix, accuracy_score, roc_curve, auc
from sklearn.ensemble import RandomForestClassifier, GradientBoostingClassifier
from sklearn.svm import SVC
from sklearn.linear_model import LogisticRegression
from sklearn.neighbors import KNeighborsClassifier
from sklearn.naive_bayes import GaussianNB
from xgboost import XGBClassifier
from catboost import CatBoostClassifier
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import Kfold, train_test_split
from sklearn.tree import DecisionTreeClassifier
import warnings
from sklearn.utils import shuffle
warnings.filterwarnings('ignore')

In [ ]: #!pip install seaborn

In [2]: dataset = pd.read_csv('Multiclass Diabetes Dataset.csv')

In [3]: dataset

Out[3]:
```

	Gender	AGE	Urea	Cr	HbA1c	Chol	TG	HDL	LDL	VLDL	BMI	Class
0	0	50	47	46	4.9	42	0.9	2.4	1.4	0.5	24.0	0
1	1	26	4.5	62	4.9	3.7	1.4	1.1	2.1	0.6	23.0	0
2	1	33	7.1	46	4.9	4.9	1.0	0.8	2.0	0.4	21.0	0
3	0	45	2.3	24	4.0	2.9	1.0	1.0	1.5	0.4	21.0	0
4	0	50	2.0	50	4.0	3.6	1.3	0.9	2.1	0.6	24.0	0
--	--	--	--	--	--	--	--	--	--	--	--	--
259	0	61	24.0	401	7.0	4.3	2.9	0.4	2.7	1.3	30.0	2
260	0	61	24.0	401	7.0	4.3	2.9	0.4	2.7	1.3	36.6	2
261	1	60	20.8	800	9.0	2.3	1.1	0.9	0.9	0.5	33.0	2
262	1	56	20.8	800	9.0	4.6	2.0	1.2	2.5	0.9	35.0	2
263	1	58	20.8	800	9.1	6.6	2.9	1.1	4.3	1.3	33.0	2

264 rows x 12 columns

Gambar 3. Proses Pengujian data sheet pada coding Anaconda

Tahapan krusial setelah proses pelatihan model adalah melakukan evaluasi mendalam untuk mengukur sejauh mana algoritma *machine learning* mampu mengenali pola data pasien secara akurat. Pada penelitian ini, efektivitas empat arsitektur algoritma yakni *Random Forest*, *Decision Tree*, *Support Vector Machine* (SVM), dan *Logistic Regression* diuji menggunakan parameter metrik standar internasional dalam dunia sains data.

Evaluasi ini tidak hanya berfokus pada nilai akurasi semata, melainkan juga membedah performa model melalui instrumen *Confusion Matrix*. Instrumen ini memberikan gambaran detail mengenai distribusi prediksi benar dan salah bagi setiap kategori diagnosis, baik itu kelas *Non-Diabetic*, *Prediabetic*, maupun *Diabetic*. Komponen evaluasi yang digunakan untuk memvalidasi keandalan model.

Precision (Presisi): Menunjukkan tingkat ketepatan model dalam memberikan prediksi positif. Dalam konteks medis, nilai presisi yang tinggi meminimalisir terjadinya kesalahan diagnosis (pasien sehat yang salah diprediksi sebagai penderita diabetes). Dalam pengembangan model klasifikasi berbasis *machine learning*, precision atau presisi merupakan parameter yang merepresentasikan tingkat keakuratan antara data yang diprediksi positif dengan realitas data yang sebenarnya positif. Secara matematis, presisi menghitung rasio hasil positif yang benar (*True Positives*) dibandingkan dengan keseluruhan hasil yang diprediksi sebagai positif oleh sistem (*True Positives* ditambah *False Positives*).

Dalam domain kesehatan, khususnya pada studi klasifikasi penyakit diabetes ini, nilai presisi memegang peranan krusial sebagai instrumen validasi reliabilitas sistem. Presisi yang tinggi menunjukkan kemampuan algoritma dalam menyaring informasi secara selektif, sehingga meminimalisir terjadinya kesalahan diagnosa berupa *False Positive* yaitu kondisi di mana seorang pasien yang sebenarnya sehat secara klinis, namun secara keliru diidentifikasi oleh model sebagai penderita diabetes atau prediabetes.

Implikasi dari nilai presisi yang rendah dalam konteks klinis dapat berdampak signifikan. Jika sistem memiliki tingkat kesalahan *false positive* yang tinggi, pasien sehat mungkin akan diarahkan untuk menjalani pemeriksaan lanjutan yang tidak perlu, mengonsumsi obat-obatan yang memiliki efek samping, atau mengalami tekanan psikologis akibat diagnosa yang tidak akurat. Oleh karena itu, pencapaian nilai presisi yang optimal pada model yang diuji (terutama pada algoritma *Random Forest*) memberikan jaminan bahwa sistem memiliki tingkat kepercayaan yang

tinggi dalam menetapkan status diagnosa, sehingga dapat menjadi alat bantu keputusan (*Decision Support System*) yang efektif bagi tenaga medis dalam mengurangi risiko malapraktik administratif berbasis data.

Recall (Sensitivitas): Merupakan metrik paling vital dalam penelitian ini, karena mengukur kemampuan model untuk menjaring seluruh pasien yang benar-benar mengidap diabetes. Nilai recall yang optimal memastikan tidak ada penderita diabetes yang terlewat atau terdeteksi sebagai pasien sehat. Dalam cakupan evaluasi performa model klasifikasi, Recall atau yang sering direferensikan sebagai Sensitivitas, merupakan parameter fundamental yang merepresentasikan kemampuan sebuah algoritma dalam mengidentifikasi secara menyeluruh seluruh data yang termasuk dalam kategori positif. Secara teknis, metrik ini menghitung proporsi keberhasilan model dalam memprediksi status pasien yang benar-benar sakit (*True Positives*) dibandingkan dengan totalitas jumlah pasien yang secara faktual memang mengidap penyakit tersebut, termasuk mereka yang secara keliru terprediksi sebagai sehat (*False Negatives*).

Dalam domain kesehatan, khususnya pada studi klasifikasi diabetes ini, *Recall* dipandang sebagai indikator keberhasilan yang jauh lebih vital dibandingkan akurasi semata. Hal ini dikarenakan konsekuensi medis yang sangat berisiko apabila terjadi kegagalan sistem dalam mengenali penderita diabetes sebuah kondisi yang dikenal sebagai False Negative. Pasien yang menyandang status ini secara medis membutuhkan intervensi atau pengobatan, namun karena sistem salah mengklasifikasikannya sebagai individu sehat, mereka berisiko tidak mendapatkan penanganan dini. Keterlambatan diagnosa tersebut dapat berujung pada komplikasi yang lebih serius, seperti kerusakan saraf, gangguan ginjal, hingga risiko kardiovaskular.

Oleh sebab itu, pencapaian nilai *Recall* yang mendekati sempurna (sebagaimana ditunjukkan oleh model *Random Forest* dalam penelitian ini) memberikan jaminan keamanan klinis yang lebih tinggi. Nilai sensitivitas yang optimal memastikan bahwa sistem memiliki "jaring" yang sangat rapat untuk

menangkap setiap pola fitur klinis seperti lonjakan HbA1c atau ketidakseimbangan profil lipid sehingga meminimalisir peluang penderita diabetes untuk terabaikan oleh sistem. Dengan demikian, model ini tidak hanya berfungsi sebagai alat komputasi, tetapi juga sebagai instrumen mitigasi risiko dalam prosedur skrining kesehatan awal yang dapat membantu tenaga medis menyelamatkan lebih banyak nyawa melalui deteksi dini yang komprehensif.

F1-Score: Memberikan gambaran harmonisasi antara precision dan recall. Nilai ini sangat berguna terutama saat menghadapi ketidakseimbangan jumlah data (imbalanced data) pada kelas tertentu seperti kategori prediabetes. Dalam evaluasi algoritma *machine learning*, F1-Score didefinisikan sebagai rata-rata harmonik (*harmonic mean*) yang mengintegrasikan dua metrik utama, yaitu *Precision* dan *Recall*, ke dalam satu nilai tunggal. Berbeda dengan rata-rata aritmatika biasa, rata-rata harmonik memberikan bobot yang lebih besar pada nilai yang lebih rendah. Hal ini berarti, untuk mendapatkan nilai F1-Score yang tinggi, sebuah model klasifikasi harus mampu mempertahankan performa yang impresif baik pada sisi ketepatan prediksi (*Precision*) maupun sisi kepekaan deteksi (*Recall*) secara bersamaan.

Urgentitas penggunaan F1-Score dalam penelitian ini menjadi sangat nyata ketika dihadapkan pada fenomena ketidakseimbangan jumlah data (imbalanced data). Dalam dataset yang digunakan, jumlah sampel untuk kategori pasien sehat (Class 0) dan penderita diabetes (Class 2) cenderung lebih dominan dibandingkan dengan kategori prediabetes (Class 1) yang jumlahnya terbatas. Pada kondisi seperti ini, nilai akurasi global seringkali bersifat manipulatif atau "menipu" karena model bisa saja terlihat akurat hanya karena berhasil menebak kelas mayoritas, padahal gagal total dalam mengenali kelas minoritas.

F1-Score hadir sebagai instrumen evaluasi yang lebih adil dan objektif. Jika sebuah model hanya mengejar *Recall* tinggi namun banyak melakukan salah diagnosa (*False Positive*), atau mengejar *Precision* tinggi namun banyak melewatkan pasien sakit (*False Negative*), maka nilai F1-Score akan secara

otomatis turun. Pencapaian nilai F1-Score yang stabil di angka tinggi—khususnya pada algoritma *Random Forest* dalam studi ini—membuktikan bahwa model tersebut memiliki ketangguhan (*robustness*) dalam mengklasifikasikan ketiga kategori diabetes secara proporsional. Secara klinis, hal ini memberikan keyakinan bahwa sistem memiliki performa yang handal tidak hanya pada kasus-kasus umum, tetapi juga pada kondisi transisi seperti prediabetes yang seringkali sulit dibedakan polanya secara statistik. Dengan demikian, F1-Score menjadi tolok ukur final yang menyatakan bahwa model yang dikembangkan telah mencapai titik optimal dalam menyeimbangkan antara efisiensi diagnosis dan keamanan pasien.

Akurasi Keseluruhan: Menunjukkan persentase total prediksi yang tepat dibandingkan dengan seluruh data uji yang ada. Akurasi Keseluruhan merupakan parameter fundamental dalam statistik *machine learning* yang merepresentasikan tingkat keberhasilan model dalam mengklasifikasikan data secara tepat di seluruh kategori yang ada. Secara matematis, metrik ini mengalkulasi rasio antara jumlah seluruh prediksi yang benar (*True Positives* dan *True Negatives*) terhadap totalitas sampel data yang digunakan dalam fase pengujian. Dalam konteks penelitian ini, akurasi memberikan gambaran umum mengenai sejauh mana algoritma mampu membedakan karakteristik antara pasien sehat, prediabetes, dan penderita diabetes secara simultan.

Meskipun akurasi sering kali dianggap sebagai indikator performa yang paling intuitif, penggunaannya dalam diagnosa medis tetap memerlukan analisis yang kritis. Akurasi yang tinggi menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat terhadap dataset yang diberikan. Namun, dalam studi ini, nilai akurasi tidak berdiri sendiri; ia divalidasi kembali melalui metrik lain seperti *Precision* dan *Recall* untuk memastikan bahwa tingginya persentase ketepatan tersebut bukan disebabkan oleh dominasi salah satu kelas mayoritas, melainkan karena keunggulan algoritma dalam mempelajari fitur-fitur klinis yang kompleks.

Pencapaian angka akurasi yang signifikan pada penelitian ini mencerminkan keberhasilan tahapan *pre-processing* dan pemilihan hiperparameter yang tepat pada

algoritma yang diuji. Secara praktis, nilai akurasi keseluruhan ini berfungsi sebagai tolok ukur efisiensi sistem dalam melakukan skrining massal. Semakin tinggi persentase akurasi yang diperoleh, semakin rendah tingkat kesalahan prediktif secara global, sehingga sistem klasifikasi ini layak dipertimbangkan sebagai instrumen pendukung bagi tenaga profesional kesehatan dalam mempercepat proses identifikasi risiko diabetes secara otomatis dan akurat.

Seluruh proses evaluasi ini dilakukan menggunakan data uji (*testing data*) yang bersifat independen. Data ini diambil dari hasil pembagian (*splitting*) dataset sekunder dengan proporsi 20%, yang sebelumnya belum pernah dilihat oleh model selama fase pembelajaran. Pendekatan ini bertujuan untuk menjamin bahwa model memiliki kemampuan generalisasi yang baik saat dihadapkan pada data klinis baru di masa depan, serta meminimalisir potensi terjadinya *overfitting*. Keseluruhan rangkaian evaluasi performa dalam penelitian ini diimplementasikan dengan memanfaatkan data uji (*testing data*) yang bersifat independen dan terisolasi dari proses pelatihan. Data ini diekstraksi melalui teknik *data splitting* terhadap dataset sekunder, di mana proporsi sebesar 20% ditetapkan secara acak sebagai representasi data baru yang belum pernah berinteraksi atau "dilihat" oleh algoritma selama fase pembelajaran (*training phase*). Pemisahan yang ketat ini merupakan prosedur standar dalam pengembangan sistem berbasis kecerdasan buatan untuk memastikan objektivitas hasil pengukuran.

Adopsi pendekatan *splitting* dengan rasio 80:20 ini memiliki tujuan strategis untuk memvalidasi kemampuan generalisasi model. Dalam disiplin *machine learning*, sebuah model dikatakan handal bukan ketika ia mampu menghafal data latihan dengan sempurna, melainkan ketika ia mampu memberikan prediksi yang akurat saat dihadapkan pada pola data klinis yang asing dan bervariasi di masa depan. Tanpa adanya data uji yang independen, terdapat risiko besar model akan mengalami fenomena *overfitting*.

Overfitting merupakan kondisi di mana algoritma terlalu menyesuaikan diri secara ekstrem terhadap kebisingan (*noise*) atau detail-detail spesifik pada data

latihan, sehingga meskipun akurasi pada data latih terlihat sempurna, kinerjanya akan anjlok saat mengolah data pasien baru di lapangan. Dengan menguji model pada 20% data yang disisihkan tersebut, penelitian ini dapat memberikan jaminan secara saintifik bahwa stabilitas akurasi yang dicapai khususnya pada model *Random Forest* adalah murni hasil dari pembelajaran pola fitur medis yang substantif (seperti korelasi HbA1c dan indeks massa tubuh), bukan sekadar kebetulan statistik. Hal ini memperkuat kredibilitas sistem untuk digunakan sebagai instrumen pendukung diagnosa medis yang bersifat prediktif dan reliabel.

Berikut adalah hasil evaluasi dari masing-masing algoritma yang diuji:

1. *Support Vector Machine (SVM)*

Model pertama yang diuji adalah *Support Vector Machine (SVM)*. Berdasarkan hasil komputasi, model ini menghasilkan akurasi sebesar 85%.

	precision	recall	f1-score	support
class 0	0.75	0.98	0.85	62
class 1	0.85	0.35	0.50	31
class 2	0.95	0.93	0.94	75
accuracy			0.85	168
macro avg	0.85	0.76	0.76	168
weighted avg	0.86	0.85	0.83	168

Gambar 4. Hasil Pengujian Data Sheet SVM Pada Coding Anaconda

Algoritma pertama yang diimplementasikan dalam pengujian ini adalah *Support Vector Machine (SVM)*. Sebagai algoritma pembelajaran terawasi (*supervised learning*), SVM bekerja dengan prinsip mencari *hyperplane* atau bidang pemisah optimal yang mampu membagi data ke dalam tiga kategori diabetes dengan margin maksimal.

Berdasarkan hasil pengujian pada data uji, model SVM mencatatkan nilai akurasi sebesar 85%.

Tabel 2. Hasil Pengujian SVM (*Support Vector Machine*)

Kelas / Kategori	Precision	Recall	F1-Score	Support
Class 0	0.75	0.98	0.85	62
Class 1	0.95	0.93	0.94	75
Class 2	0.85	0.35	0.50	31
Rata-rata Makro	0.85	0.76	0.76	168
Rata-rata Tertimbang	0.86	0.85	0.83	168
Akurasi Keseluruhan	-	-	-	85%

Berdasarkan hasil pengujian yang tersaji pada tabel di atas, model *Support Vector Machine* (SVM) mencatatkan tingkat akurasi keseluruhan sebesar 85%. Meskipun angka ini menunjukkan performa yang cukup kompeten secara global, tinjauan mendalam pada setiap kelas (Class 0, 1, dan 2) mengungkapkan dinamika klasifikasi yang bervariasi, terutama terkait kemampuan model dalam menangani distribusi data yang tidak merata.

Secara keseluruhan, capaian 85% ini memposisikan SVM sebagai model dengan kinerja menengah dalam studi ini. Hasil ini memberikan landasan perbandingan yang penting untuk memahami mengapa model berbasis *ensemble learning* (seperti *Random Forest*) kemudian mampu memberikan peningkatan akurasi yang lebih signifikan pada karakteristik dataset yang sama.

2. *Random Forest*

Model kedua, *Random Forest*, menunjukkan performa yang sangat luar biasa dan merupakan model terbaik dalam pengujian ini. Akurasi yang didapatkan mencapai 99%.

	precision	recall	f1-score	support
class 0	0.98	1.00	0.99	62
class 1	0.97	1.00	0.98	31
class 2	1.00	0.97	0.99	75
accuracy			0.99	168
macro avg	0.98	0.99	0.99	168
weighted avg	0.99	0.99	0.99	168

Gambar 5. Hasil Pengujian Data Sheet *Random Forest* Coding Anaconda

Pencapaian akurasi yang sangat tinggi ini tidak terlepas dari karakteristik fundamental *Random Forest* sebagai algoritma berbasis *Ensemble Learning*. Berbeda dengan *Decision Tree* tunggal yang rentan terhadap kesalahan prediksi pada data baru, *Random Forest* bekerja dengan membangun puluhan hingga ratusan pohon keputusan secara paralel dan menggabungkan hasilnya melalui mekanisme *voting*.

Pencapaian akurasi sebesar 99% pada model *Random Forest* sering kali menimbulkan kecurigaan akademis terkait fenomena *overfitting*, di mana model mungkin hanya "menghafal" karakteristik spesifik dari dataset latih tanpa mampu melakukan generalisasi. Namun, dalam pengujian ini, performa tersebut terbukti stabil karena didukung oleh arsitektur internal *Random Forest* yang secara inheren dirancang untuk mereduksi varians tinggi yang biasanya ditemukan pada pohon keputusan tunggal (*Decision Tree*).

Salah satu kunci utama ketangguhan model ini adalah implementasi teknik *Bagging (Bootstrap Aggregating)*. Dalam proses ini, *Random Forest* tidak melatih

seluruh pohon menggunakan dataset yang sama secara utuh. Sebaliknya, algoritma menciptakan beberapa subset data yang berbeda melalui pengambilan sampel secara acak dengan pengembalian (*replacement*). Dampaknya, setiap pohon keputusan dalam "hutan" tersebut mempelajari pola dari sudut pandang data yang sedikit berbeda. Diversitas ini menciptakan sekumpulan model yang independen namun saling melengkapi.

Secara teknis, efikasi sebesar 99% ini memposisikan *Random Forest* sebagai solusi paling andal untuk sistem automasi diagnosa diabetes. Tingkat kesalahan yang hanya sebesar 1% menunjukkan bahwa model ini memiliki reliabilitas klinis yang sangat kuat untuk membantu tenaga medis dalam melakukan klasifikasi pasien secara cepat, akurat, dan menyeluruh di semua fase penyakit.

Tabel 3. Hasil Pengujian *Random Forest*

Kelas / Kategori	Precision	Recall	F1-Score	Support
Class 0	0.98	1.00	0.99	62
Class 1	0.97	1.00	0.98	31
Class 2	1.00	0.97	0.99	75
Rata-rata Makro	0.98	0.99	0.99	168
Rata-rata Tertimbang	0.99	0.99	0.99	168
Akurasi Keseluruhan	-	-	-	99%

Hampir seluruh klasifikasi pada model ini berjalan sempurna. Hal ini membuktikan keunggulan *Random Forest* yang bekerja berdasarkan konsep *ensemble learning*, yaitu menggabungkan banyak pohon keputusan (*decision tree*) untuk meningkatkan akurasi prediksi dan meminimalisir risiko terjadinya *overfitting*. Berdasarkan hasil komputasi yang direpresentasikan pada tabel di atas, model *Random Forest* menunjukkan performa yang sangat superior dengan capaian Akurasi Keseluruhan sebesar 99%.

Nilai ini menunjukkan bahwa hampir seluruh data uji (168 sampel) berhasil diklasifikasikan dengan tepat ke dalam kategori medis yang sesuai. Berbeda dengan model sebelumnya, *Random Forest* menunjukkan stabilitas yang luar biasa di seluruh parameter, baik pada kelas mayoritas maupun kelas minoritas.

Model *Random Forest* menunjukkan performa yang sangat superior dengan capaian Akurasi Keseluruhan (*Overall Accuracy*) sebesar 99%. Pencapaian angka yang hampir menyentuh titik sempurna ini memberikan indikasi teknis bahwa model memiliki kapabilitas generalisasi yang sangat tinggi terhadap karakteristik dataset diabetes yang digunakan. Secara kuantitatif, nilai ini merepresentasikan bahwa dari total 168 sampel data uji yang bersifat independen, hampir seluruhnya berhasil dipetakan secara presisi ke dalam kategori medis yang sesuai, baik itu kategori sehat, prediabetes, maupun diabetes.

Pada kategori pasien sehat atau Class 0 (Non-Diabetic), model *Random Forest* menunjukkan performa yang nyaris tanpa celah dengan pencapaian nilai Recall sempurna sebesar 1.00 (100%) dan tingkat Precision sebesar 0.98. Secara teknis, nilai *Recall* yang menyentuh angka absolut ini mengindikasikan bahwa algoritma memiliki sensitivitas yang luar biasa tinggi dalam menjaring seluruh subjek non-diabetes di dalam dataset uji. Dalam implementasi praktis, hal ini berarti tidak ada satu pun individu sehat yang luput dari klasifikasi model; seluruhnya berhasil diidentifikasi dengan tepat sesuai dengan label kebenaran (*ground truth*).

Pencapaian pada kategori prediabetes merupakan sorotan utama dalam penelitian ini. Meskipun hanya memiliki support 31 sampel (paling sedikit), model ini mampu meraih Recall 1.00 dan Precision 0.97. Keberhasilan ini membuktikan bahwa *Random Forest* sangat efektif dalam menangani *imbalanced data*. Model secara presisi mampu menangkap sinyal-sinyal klinis pada fase transisi prediabetes yang biasanya sulit dibedakan oleh algoritma linier, sehingga meminimalisir risiko pasien kehilangan "jendela kesempatan" untuk penanganan dini.

Pada kategori pasien penderita diabetes atau Class 2 (Diabetic), model *Random Forest* mencatatkan pencapaian teknis yang sangat impresif dengan raihan

Precision sempurna sebesar 1.00 (100%). Secara terminologi statistik, nilai presisi absolut ini memberikan jaminan bahwa setiap prediksi "Diabetic" yang dikeluarkan oleh sistem sepenuhnya akurat dan sesuai dengan label kebenaran (*ground truth*) pada data lapangan. Dengan kata lain, tidak ditemukan adanya kasus *False Positive* pada kategori ini; sistem tidak pernah secara keliru mendiagnosa pasien sehat atau prediabetes sebagai penderita diabetes kronis.

3. *Decision Tree*

Model ketiga menggunakan algoritma *Decision Tree*. Meskipun bekerja dengan struktur keputusan tunggal, algoritma ini mampu menghasilkan akurasi yang sangat memuaskan, yakni 98%.

	precision	recall	f1-score	support
class 0	0.97	0.98	0.98	62
class 1	1.00	0.97	0.98	31
class 2	0.97	0.97	0.97	75
accuracy			0.98	168
macro avg	0.98	0.97	0.98	168
weighted avg	0.98	0.98	0.98	168

Gambar 6. Hasil Pengujian Data Sheet Decision Tree Pada Coding Anaconda

Tabel 4. Hasil Pengujian *Decision Tree*

Kelas / Kategori	Precision	Recall	F1-Score	Support
Class 0	0.97	0.98	0.98	62
Class 1	1.00	0.97	0.98	31
Class 2	0.97	0.97	0.97	75
Rata-rata Makro	0.98	0.97	0.98	168
Rata-rata Tertimbang	0.98	0.98	0.98	168
Akurasi Keseluruhan	-	-	-	98%

Model ini menunjukkan keseimbangan yang sangat baik di seluruh kelas, menjadikannya salah satu metode yang andal untuk memproses parameter data medis secara kompleks. Berdasarkan hasil pengujian yang dipaparkan pada tabel di atas, model ini menunjukkan performa yang sangat kompetitif dengan capaian Akurasi Keseluruhan sebesar 98%. Angka ini merepresentasikan reliabilitas model yang sangat tinggi, di mana sistem hanya melakukan kesalahan klasifikasi pada sebagian kecil dari total 168 sampel data uji. Performa ini menunjukkan bahwa struktur pohon keputusan yang terbentuk mampu mengekstraksi aturan logis (*rules*) yang sangat kuat dari parameter klinis pasien.

Model menunjukkan tingkat keberhasilan yang sangat stabil pada kategori pasien sehat dengan nilai Recall 0.98 dan Precision 0.97. Capaian ini menandakan bahwa model hampir tidak melewatkan subjek normal dalam proses klasifikasi. Integritas data pada kelas ini sangat krusial agar sistem tidak memberikan beban pemeriksaan lanjutan yang tidak perlu bagi individu yang sebenarnya sehat.

Pada kategori pasien sehat atau Class 0 (Non-Diabetic), model menunjukkan performa yang sangat solid dan stabil dengan perolehan nilai Recall sebesar 0.98 dan Precision sebesar 0.97. Secara teknis, nilai *Recall* 0.98 mengindikasikan bahwa model memiliki sensitivitas yang sangat tinggi dalam mendeteksi populasi normal; dari seluruh subjek yang benar-benar sehat dalam dataset uji, sebanyak 98% berhasil diidentifikasi dengan tepat oleh sistem. Capaian ini memberikan gambaran bahwa algoritma mampu mengenali pola parameter biokimiawi pada individu non-diabetes dengan tingkat kesalahan yang sangat marjinal.

Pencapaian pada kategori prediabetes menjadi aspek yang paling impresif dari model ini. Meskipun memiliki jumlah sampel paling terbatas (support 31), model berhasil meraih Precision sempurna sebesar 1.00. Hal ini berarti setiap kali model memprediksi seorang pasien berada pada fase prediabetes, prediksi tersebut terbukti benar 100% tanpa adanya kesalahan *False Positive*. Nilai Recall 0.97 juga menunjukkan bahwa model sangat sensitif dalam mendeteksi fase transisi ini, yang merupakan tahapan vital untuk intervensi preventif.

Kategori prediabetes sering kali menjadi tantangan terbesar dalam klasifikasi medis karena karakteristik datanya yang berada di zona transisi, di mana nilai parameter klinis sering kali bersinggungan tipis dengan kategori sehat maupun diabetes kronis. Terlebih lagi, kategori ini memiliki keterbatasan jumlah sampel dengan support hanya 31 data, menjadikannya kelas minoritas dalam penelitian ini.

Pada kategori penderita diabetes, model menunjukkan konsistensi dengan nilai Precision 0.97 dan Recall 0.97. Keseimbangan metrik ini menunjukkan bahwa model memiliki pemahaman yang matang dalam mengidentifikasi gejala diabetes kronis. Margin kesalahan 3% pada kelas ini biasanya disebabkan oleh variasi biologis pasien yang sangat dinamis, namun secara keseluruhan, model tetap memberikan jaminan diagnosa yang sangat akurat bagi penderita diabetes.

4. *Logistic Regression*

Dalam sintaks kode (*script*) yang dijalankan, metode yang memodelkan kategori ini menggunakan pustaka *LogisticRegression* yang bekerja layaknya regresi linier logistik pada klasifikasi. Sesuai penamaan yang diajukan, laporan ini menggunakan istilah Linear Regression. Model keempat mencatat akurasi terendah di antara metode lainnya, yaitu sebesar 79%.

	precision	recall	f1-score	support
class 0	0.70	0.98	0.82	62
class 1	0.75	0.10	0.17	31
class 2	0.90	0.92	0.91	75
accuracy			0.79	168
macro avg	0.78	0.67	0.63	168
weighted avg	0.80	0.79	0.74	168

Gambar7. Hasil Pengujian Data Sheet Logic Regresion Pada Coding Anaconda

Tabel 5. Hasil Pengujian *Logistic Regression*

Kelas / Kategori	Precision	Recall	F1-Score	Support
Class 0	0.70	0.98	0.82	62
Class 1	0.75	0.10	0.17	31
Class 2	0.90	0.92	0.91	75
Rata-rata Makro	0.78	0.67	0.63	168
Rata-rata Tertimbang	0.80	0.79	0.74	168
Akurasi Keseluruhan	-	-	-	79%

Berdasarkan tabel metrik evaluasi di atas, model menunjukkan capaian Akurasi Keseluruhan sebesar 79%. Meskipun angka ini terlihat cukup tinggi secara superfisial, analisis mendalam terhadap tiap kategori klinis mengungkapkan adanya disparitas performa yang sangat signifikan, terutama pada kemampuan model dalam mendeteksi fase transisi penyakit.

Class 0 (Non-Diabetic): Dengan Recall sebesar 0.98, model sangat sukses menjangkit populasi sehat. Namun, nilai Precision yang rendah (0.70) mengindikasikan banyaknya kesalahan *False Positive*, di mana subjek dari kelas lain (kemungkinan prediabetes) secara keliru dianggap sehat.

Titik lemah paling krusial dari model ini terletak pada Class 1 (Prediabetic). Meskipun memiliki *Precision* 0.75, nilai Recall sangat rendah yaitu 0.10 (10%). Hal ini merupakan temuan yang mengkhawatirkan secara klinis karena berarti dari 31 pasien prediabetes, model hanya mampu mendeteksi 3 orang secara tepat, sementara 28 orang lainnya gagal teridentifikasi (*False Negative*). Rendahnya nilai *Recall* ini membuktikan bahwa model mengalami kesulitan besar dalam membedakan sinyal transisi yang halus pada fase prediabetes. Model cenderung "menyerah" pada kelas minoritas ini dan secara bias mengklasifikasikan mereka ke dalam kategori sehat (Class 0) atau diabetes (Class 2). Secara medis, kegagalan ini berakibat fatal karena pasien kehilangan kesempatan untuk melakukan intervensi preventif sebelum penyakit memburuk.

Ketidakmampuan model dalam menangani ketidakseimbangan data (*imbalanced data*) tercermin jelas pada nilai Rata-rata Makro (Macro Average). Macro Average F1-Score (0.63): Nilai ini jauh lebih rendah dibandingkan akurasi keseluruhan (0.79). Disparitas yang lebar ini membuktikan bahwa model mengalami bias kelas. Akurasi 79% tersebut hanyalah "semu" karena didorong oleh keberhasilan pada kelas mayoritas, sementara pada kelas minoritas (prediabetes), model hampir tidak berfungsi.

Secara teknis, rendahnya performa pada fase transisi menunjukkan bahwa batas keputusan (*decision boundary*) yang dibentuk oleh model tidak cukup fleksibel untuk menangkap pola non-linier pada data prediabetes. Model ini belum mampu melakukan generalisasi yang adil terhadap seluruh spektrum kondisi pasien.

Secara klinis, model dengan karakteristik seperti ini kurang direkomendasikan sebagai sistem pakar deteksi dini. Tingginya risiko pasien prediabetes yang tidak terdeteksi (90% luput) dapat memberikan rasa aman palsu kepada pasien, yang pada akhirnya justru meningkatkan beban kesehatan masyarakat karena ledakan kasus diabetes kronis di masa depan yang tidak tertangani sejak dini.

4.2. Pembahasan

Berdasarkan rekapitulasi nilai akurasi pada pengujian empat algoritma *machine learning*, ditemukan perbedaan kapabilitas yang signifikan dalam mengklasifikasikan multi-kelas penyakit diabetes. Perbandingan performa akurasi adalah sebagai berikut:

1. SVM: 85%
2. *Random Forest*: 99%
3. *Decision Tree*: 98%
4. *Linear Regression*: 79%

Ternyata, performa terbaik dengan tingkat akurasi tertinggi (99%) didapatkan pada algoritma *Random Forest*. Hasil ini secara praktis mengonfirmasi teori empiris bahwa metode *Random Forest* sangat efektif dalam mengenali pola *non-linear* pada parameter biologis pasien secara terukur dan stabil. Kemampuannya untuk mengekstrak korelasi yang tepat dari *feature* klinis primer seperti Glukosa Darah, Tekanan Darah, *Body Mass Index* (BMI), dan Kadar Insulin memungkinkan sistem untuk mengenali berbagai kategori gangguan metabolisme dengan detail.

Dari hasil komputasi tersebut, ditemukan bahwa performa terbaik dengan tingkat akurasi tertinggi (99%) didapatkan pada algoritma *Random Forest*. Hasil ini secara praktis mengonfirmasi teori empiris bahwa metode *ensemble learning* seperti *Random Forest* memiliki efektivitas yang jauh lebih tinggi dibandingkan model linier atau pohon tunggal dalam mengenali pola *non-linear* pada parameter biologis pasien. Data medis cenderung memiliki hubungan yang kompleks dan saling bergantung satu sama lain; misalnya, pengaruh indeks massa tubuh (BMI) terhadap kadar glukosa tidak selalu bersifat garis lurus, melainkan dipengaruhi oleh variabel lain seperti usia atau tekanan darah.

Kemampuan *Random Forest* untuk mengekstrak korelasi yang tepat dari *feature* klinis primer termasuk Glukosa Darah, Tekanan Darah, *Body Mass Index* (BMI), dan Kadar Insulin memungkinkan sistem untuk mengenali berbagai

kategori gangguan metabolisme dengan tingkat detail yang sangat tinggi. Hal ini disebabkan oleh mekanisme internal algoritma yang membangun ratusan pohon keputusan secara paralel. Setiap pohon memberikan "suara" (*vote*) untuk menentukan kelas akhir, sehingga meminimalisir kesalahan individual yang mungkin terjadi pada satu pohon keputusan saja.

Di sisi lain, model linear konvensional (akurasi 79%) terbukti kurang andal untuk dataset klinis diabetes yang variabilitas variabelnya amat tinggi dan tumpang tindih (*overlapping* antar kelas). Algoritma konvensional acapkali kesulitan mencari garis linear yang secara definitif mampu membedakan Kelas 1 dengan jelas tanpa *bias* dari kelas lainnya. Secara kontras, algoritma seperti Linear Regression (79%) dan SVM (85%) menunjukkan performa yang tertinggal. Rendahnya akurasi pada kedua model ini mengindikasikan bahwa batas keputusan (*decision boundary*) yang bersifat linier atau berbasis fungsi kernel tertentu tidak cukup fleksibel untuk memetakan keragaman data pasien secara menyeluruh, terutama pada kelas prediabetes yang sering kali menjadi "zona abu-abu".

Superioritas *Random Forest* dalam penelitian ini membuktikan bahwa pendekatan yang menggabungkan banyak model (*ensemble*) mampu menghasilkan tingkat stabilitas prediktif dan generalisasi data yang luar biasa. Capaian akurasi 99% ini tidak hanya sekadar angka statistik, melainkan representasi dari sebuah sistem yang telah mencapai tingkat kematangan teknis yang andal untuk digunakan sebagai instrumen pendukung keputusan klinis dalam deteksi dini penyakit diabetes.

Oleh karena itu, pendekatan multi-klasifikasi terbukti jauh lebih optimal saat menggunakan arsitektur gabungan (seperti *Random Forest*). Model ini terbukti dapat digunakan untuk memprediksi tipe diabetes pada pasien baru berdasarkan pola data yang telah dipelajari dengan tingkat kepastian ilmiah yang paling solid. . Keunggulan ini bukan sekadar hasil dari komputasi yang intensif, melainkan buah dari strategi mitigasi bias dan varians yang melekat pada metode *bagging*. Dalam konteks data medis yang sering kali memiliki tingkat kebisingan (*noise*) dan

pencilan (*outliers*) yang tinggi, model ini terbukti mampu mempertahankan konsistensi prediksi tanpa terjebak dalam fenomena *overfitting*.

Model ini terbukti sangat andal untuk digunakan dalam memprediksi tipe diabetes pada pasien baru berdasarkan pola data yang telah dipelajari selama proses pelatihan dengan tingkat kepastian ilmiah yang paling solid. Kepastian ini bersumber dari mekanisme *majority voting*, di mana keputusan akhir tidak hanya bergantung pada satu pohon keputusan yang rentan terhadap galat, melainkan hasil konsensus dari ratusan iterasi pohon yang independen. Hal ini memberikan jaminan bahwa generalisasi yang dilakukan oleh model terhadap data yang belum pernah dilihat sebelumnya (*unseen data*) memiliki derajat akurasi yang tetap tinggi dan stabil.

Dalam perspektif jangka panjang, efikasi model ini menawarkan fondasi yang kokoh bagi pengembangan teknologi kedokteran presisi (*precision medicine*). Dengan tingkat kepastian 99%, model ini tidak hanya berfungsi sebagai alat bantu administratif, tetapi juga sebagai instrumen saintifik yang mampu meminimalisir subjektivitas manusia dalam proses diagnosa. Hal ini memastikan bahwa setiap pasien baru akan mendapatkan penilaian risiko yang objektif berdasarkan parameter biologis yang terukur, sehingga memfasilitasi pengambilan keputusan medis yang lebih cepat, akurat, dan berbasis data (*data-driven*).

1. Sinkronisasi & Penyesuaian Algoritma

Langkah pertama adalah menyelaraskan apa yang tertulis di Bab I-III dengan hasil eksperimen di Bab IV. Karena hasil kode menunjukkan performa yang sangat baik pada *Random Forest* dan *Decision Tree*. Langkah fundamental dalam penyusunan laporan akhir ini adalah menyelaraskan kerangka konseptual yang telah dirumuskan pada Bab I hingga Bab III dengan temuan objektif yang dihasilkan dari eksperimen pada Bab IV. Berdasarkan hasil komputasi yang telah dilakukan, ditemukan bahwa performa model menunjukkan efikasi yang sangat tinggi pada penggunaan algoritma berbasis pohon, yakni *Random Forest* dan *Decision Tree*. Oleh karena itu, diperlukan sinkronisasi yang presisi untuk

memastikan bahwa argumentasi yang dibangun sejak awal selaras dengan realitas data yang ditemukan.

"Meskipun pada perancangan awal penelitian ini memfokuskan pada penggunaan *Artificial Neural Network* (ANN), dalam tahap implementasi dilakukan komparasi tambahan dengan algoritma berbasis *tree* (pohon keputusan) seperti *Random Forest* dan *Decision Tree*. Hal ini dilakukan karena dataset medis yang digunakan memiliki karakteristik fitur tabular yang sangat kuat, di mana algoritma berbasis *ensemble learning* seringkali memberikan hasil yang lebih stabil dan interpretabel dibandingkan arsitektur saraf tiruan untuk jumlah data yang terbatas."

Meskipun pada perancangan awal penelitian ini memfokuskan observasi pada penggunaan *Artificial Neural Network* (ANN) sebagai arsitektur utama, dalam tahap implementasi dilakukan ekspansi metodologis melalui komparasi tambahan dengan algoritma berbasis *tree* (pohon keputusan), khususnya *Random Forest* dan *Decision Tree*. Penambahan ini bukan sekadar upaya pembandingan, melainkan langkah strategis untuk menguji efektivitas model terhadap karakteristik spesifik dari dataset medis yang digunakan.

Keputusan untuk mengintegrasikan algoritma berbasis *ensemble learning* ini didasarkan pada beberapa pertimbangan teknis yang fundamental:

- a. Karakteristik Data Tabular: Dataset medis dalam penelitian ini memiliki struktur fitur tabular yang sangat kuat, di mana hubungan antar-variabel (seperti korelasi glukosa terhadap insulin) sering kali memiliki batasan keputusan (*decision boundary*) yang tegas dan non-linear. Dalam literatur *machine learning* terkini, algoritma berbasis pohon sering kali terbukti lebih superior dalam menangani data tabular dibandingkan arsitektur saraf tiruan (ANN) yang cenderung memerlukan data dalam skala masif untuk mencapai konvergensi optimal.

- b. Stabilitas pada Sampel Terbatas: Mengingat jumlah data medis yang bersifat finit (terbatas), ANN memiliki risiko tinggi terjebak dalam fenomena *overfitting* atau kesulitan dalam proses generalisasi. Sebaliknya, mekanisme Bagging pada *Random Forest* bekerja dengan membangun ratusan pohon keputusan secara independen, yang secara efektif mereduksi varians dan meningkatkan stabilitas prediksi, bahkan pada dataset dengan jumlah sampel yang tidak terlalu besar.
- c. Interpretabilitas Klinis (Explainability): Salah satu kelemahan utama ANN adalah sifatnya yang menyerupai "kotak hitam" (*black box*), di mana sulit bagi tenaga medis untuk memahami alasan di balik sebuah keputusan diagnosa. Algoritma berbasis *tree* menawarkan tingkat interpretabilitas yang lebih tinggi melalui visualisasi *feature importance*. Hal ini memungkinkan peneliti untuk melacak parameter klinis mana (misalnya HbA1c atau BMI) yang paling dominan dalam menentukan klasifikasi prediabetes, sehingga hasil penelitian ini memiliki nilai kegunaan praktis yang lebih tinggi di lingkungan klinis.

Dengan melakukan komparasi ini, penelitian tidak hanya terjebak pada satu paradigma algoritma, tetapi secara objektif membuktikan bahwa untuk kasus klasifikasi multi-kelas diabetes ini, arsitektur berbasis *tree* memberikan hasil yang lebih stabil, akurat (mencapai 98-99%), dan secara saintifik lebih mudah dipertanggungjawabkan akurasi dalam konteks medis profesional.

2. Interpretasi Klinis (Pemetaan Label Kelas)

Agar pembaca paham apa itu *Class 0*, *1*, dan *2*, kita harus memetakan hasil tersebut ke dalam diagnosis medis sesuai dataset diabetes yang digunakan.

Tabel 6. Pemetaan Label Kelas

Label Model	Interpretasi Medis	Kadar HbA1c (%)	Parameter Pendukung (Klinis)	Status Risiko
Class 0	Non-Diabetic (Sehat)	< 5.7	Urea & Kreatinin normal; BMI < 25; Kolesterol (Chol) cenderung stabil.	Rendah
Class 1	Prediabetic	5.7 – 6.4	Kenaikan pada kadar Chol & TG; BMI mulai memasuki kategori <i>Overweight</i> .	Sedang (Waspada)
Class 2	Diabetic	> 6.5	Urea (> 4.7) & Kreatinin (> 64) tinggi; BMI > 30 (Obese); HDL rendah.	Tinggi

"Berdasarkan hasil klasifikasi, Class 0 merepresentasikan pasien sehat, Class 1 sebagai prediabetes, dan Class 2 sebagai penderita diabetes. Tingginya akurasi pada Class 2 menunjukkan bahwa fitur-fitur klinis seperti kadar HbA1c dan BMI memiliki batas pemisah yang sangat jelas pada penderita diabetes dibandingkan dengan kondisi normal."

Setelah menyajikan tabel, terdapat narasi penjelasan seperti berikut:

- a. Karakteristik Class 2 (*Diabetic*): Berdasarkan data input, Class 2 tidak hanya ditandai dengan HbA1c yang tinggi, tetapi juga adanya indikasi komplikasi pada fungsi ginjal yang terlihat dari peningkatan nilai Urea dan Cr (Kreatinin). Model *Random Forest* sangat akurat mendeteksi kelas ini karena kombinasi fitur metabolik dan ginjal memberikan pola yang sangat unik.
- b. Karakteristik Class 1 (*Prediabetic*): Kelas ini merupakan fase transisi. Dalam dataset Anda, Class 1 sering kali memiliki nilai yang tumpang tindih (*overlap*) dengan Class 0. Hal ini menjelaskan mengapa model Linear

Regression hanya mendapatkan akurasi rendah; karena model tersebut mencoba menarik garis lurus, sementara kondisi Prediabetes membutuhkan algoritma yang mampu melihat hubungan non-linear.

- c. Korelasi BMI (*Body Mass Index*): Terdapat kecenderungan bahwa semakin tinggi angka Class (dari 0 ke 2), rata-rata nilai BMI dalam dataset juga meningkat. Ini menunjukkan bahwa obesitas merupakan variabel pendukung yang signifikan dalam proses klasifikasi penyakit diabetes pada penelitian ini.

3. Analisis Kepentingan Fitur (*Feature Importance*)

Ini adalah bagian paling penting untuk menunjukkan sisi "Elektro" atau "Teknis" dalam mengolah data medis. *Random Forest* memungkinkan kita melihat variabel mana yang paling berpengaruh.

"Melalui algoritma *Random Forest*, dilakukan analisis tingkat kepentingan fitur untuk mengetahui variabel medis mana yang paling berkontribusi dalam diagnosa. Hasilnya menunjukkan bahwa variabel HbA1c, BMI, dan kadar Gula Darah menempati posisi teratas. Hal ini sejalan dengan teori medis yang menyatakan bahwa HbA1c merupakan indikator rata-rata gula darah jangka panjang yang paling akurat dalam menentukan status diabetes seseorang."

Berdasarkan hasil ekstraksi fitur pada model *Random Forest* yang dikembangkan, ditemukan bahwa variabel HbA1c, BMI (*Body Mass Index*), dan kadar Gula Darah secara konsisten menempati posisi teratas dalam hirarki kepentingan. Hal ini memberikan beberapa temuan penting:

- a. HbA1c sebagai Indikator Utama: Penempatan HbA1c di posisi puncak sejalan dengan teori medis fundamental. Sebagai indikator yang merepresentasikan rata-rata kadar glukosa darah dalam jangka waktu 2-3 bulan terakhir, HbA1c memberikan gambaran stabilitas glikemik yang jauh lebih akurat dibandingkan tes gula darah sewaktu. Model secara cerdas

menangkap bahwa fluktuasi pada HbA1c adalah sinyal paling kuat dalam membedakan antara individu sehat, prediabetes, dan diabetes kronis.

- b. Korelasi BMI dan Gangguan Metabolik: Tingginya bobot kepentingan pada variabel BMI menegaskan korelasi teknis antara komposisi tubuh dengan resistensi insulin. Algoritma berhasil memetakan bahwa peningkatan indeks massa tubuh sering kali menjadi pemicu utama disfungsi metabolisme, sehingga variabel ini menjadi pemisah (*splitter*) yang efektif dalam pohon keputusan untuk mengidentifikasi kelompok berisiko tinggi.
- c. Integrasi Multidimensi: Selain variabel utama, keberadaan kadar Gula Darah dan parameter pendukung lainnya dalam jajaran fitur penting menunjukkan bahwa model tidak hanya bergantung pada satu indikator tunggal. Sebaliknya, *Random Forest* membangun relasi multidimensi di mana interaksi antar-fitur tersebut diolah untuk meminimalisir kesalahan diagnosa.

4. Analisis Ketimpangan Data (*Handling Imbalance*)

Dalam proses pengembangan model klasifikasi diabetes ini, salah satu tantangan teknis yang paling signifikan adalah adanya ketimpangan jumlah data (*data imbalance*). Distribusi sampel pada dataset tidak tersebar secara merata, di mana kategori Prediabetes (Class 1) merupakan kelas minoritas dengan hanya memiliki 31 sampel. Jumlah ini jauh lebih sedikit jika dibandingkan dengan kategori pasien sehat (62 sampel) maupun kategori diabetes kronis (75 sampel). Ketimpangan ini secara teoretis sering menjadi penyebab kegagalan model dalam melakukan generalisasi pada kelas yang krusial namun berjumlah sedikit.

"Terdapat tantangan berupa ketimpangan jumlah data (*data imbalance*), di mana sampel untuk kategori Prediabetes (Class 1) jauh lebih sedikit (31 sampel) dibandingkan kategori lainnya. Pada model SVM dan Regresi Linear, hal ini menyebabkan nilai *Recall* yang sangat rendah (0.10 - 0.35), karena model cenderung memprediksi data ke kelas yang mayoritas. Namun, algoritma Random Forest berhasil mengatasi masalah ini melalui mekanisme

sub-sampling internalnya, sehingga tetap mampu mengenali Class 1 dengan *Recall* 1.00 (sempurna)."

Analisis terhadap hasil pengujian menunjukkan dampak yang sangat kontras antara model linier dan model berbasis *ensemble* dalam menangani fenomena ini:

- a. Kegagalan Model SVM dan Regresi Linear: Pada model SVM dan Regresi Linear, ketimpangan data ini menyebabkan penurunan performa yang drastis, ditandai dengan nilai *Recall* yang sangat rendah pada kisaran 0.10 hingga 0.35. Hal ini terjadi karena model-model tersebut memiliki kecenderungan untuk meminimalkan *error* global dengan cara mengarahkan prediksi ke arah kelas mayoritas demi mengejar angka akurasi yang tinggi secara superfisial. Akibatnya, pasien pada fase prediabetes (Class 1) sering kali salah diklasifikasikan sebagai sehat atau diabetes, karena batas keputusan (*decision boundary*) yang dibentuk oleh model linier tidak cukup sensitif untuk menangkap pola unik dari data minoritas.
- b. Keunggulan Mekanisme Random Forest: Sebaliknya, algoritma Random Forest menunjukkan ketangguhan (*robustness*) yang luar biasa dalam mengatasi masalah ketimpangan ini. Model ini berhasil mengenali Class 1 dengan tingkat keberhasilan sempurna, yakni *Recall* 1.00. Keberhasilan ini dimungkinkan oleh mekanisme internal *Random Forest* yang melakukan *Bootstrapping* dan *Sub-sampling*. Dalam proses pembangunan setiap pohon keputusan, algoritma secara acak mengambil sampel data dengan penggantian, sehingga peluang fitur-fitur dari kelas minoritas untuk terpilih dan dipelajari menjadi tetap terjaga.

Selain itu, karakteristik *Random Forest* yang mengagregasi ratusan pohon keputusan memungkinkan model untuk membangun aturan keputusan yang lebih spesifik dan tajam bagi kelas minoritas. Dengan demikian, meskipun jumlah datanya terbatas, model tetap mampu mengekstraksi informasi penting tanpa terdistorsi oleh dominasi kelas mayoritas. Secara klinis, kemampuan model untuk mengatasi *imbalance* ini sangatlah vital, karena menjamin bahwa kelompok pasien

di fase transisi (prediabetes) tidak terabaikan dalam sistem skrining kesehatan otomatis.

5. Validasi dengan K-Fold Cross Validation

Untuk membuktikan bahwa akurasi 99% bukan karena "beruntung" saat pembagian data.

"Untuk menjamin validitas hasil, penelitian ini menerapkan *5-Fold Cross Validation*. Data latih dibagi menjadi 5 bagian, di mana secara bergantian setiap bagian menjadi data uji. Hasil rata-rata akurasi yang tetap konsisten di angka 98-99% menunjukkan bahwa model *Random Forest* memiliki kemampuan generalisasi yang sangat baik dan tidak mengalami *overfitting* (menghafal data), sehingga handal jika diimplementasikan pada data pasien baru."

Untuk menjamin bahwa tingkat akurasi tinggi yang dicapai (99%) bukan merupakan hasil dari kebetulan statistik saat pembagian data (*data splitting*), penelitian ini menerapkan mekanisme *5-Fold Cross Validation*. Prosedur ini merupakan standar rigoritas dalam *machine learning* untuk memvalidasi bahwa model memiliki performa yang konsisten dan reliabel di seluruh distribusi dataset. Dalam metode ini, dataset secara sistematis dibagi menjadi 5 sub-bagian (*fold*) yang sama besar.

Proses validasi dilakukan melalui 5 iterasi eksperimen yang berbeda. Pada setiap iterasi, satu bagian data (20%) dialokasikan secara eksklusif sebagai data uji (*test set*), sementara empat bagian lainnya (80%) digunakan sebagai data latih (*training set*). Mekanisme ini memastikan bahwa setiap sampel data dalam penelitian ini pernah merasakan peran sebagai data uji dan data latih, sehingga evaluasi performa model dilakukan secara menyeluruh terhadap seluruh variasi parameter medis yang tersedia.

Hasil pengujian menunjukkan bahwa rata-rata akurasi yang dihasilkan tetap konsisten berada di rentang 98% hingga 99% di seluruh *fold*. Konsistensi angka ini memberikan bukti ilmiah yang kuat mengenai dua aspek teknis utama:

- a. Kemampuan Generalisasi yang Unggul: Model *Random Forest* terbukti tidak hanya mampu mengenali pola pada satu porsi data tertentu, tetapi mampu melakukan generalisasi pola klinis secara universal terhadap data yang belum pernah dilihat sebelumnya (*unseen data*). Hal ini menjadikannya sangat handal untuk diimplementasikan pada data pasien baru di lingkungan rumah sakit.
- b. Mitigasi Overfitting: Jika sebuah model mengalami *overfitting* (hanya menghafal data latih), maka akurasi akan terjun bebas saat diuji pada *fold* yang berbeda. Namun, stabilitas nilai akurasi pada penelitian ini mengonfirmasi bahwa model benar-benar mempelajari fitur-fitur esensial (seperti pola HbA1c dan BMI) dan tidak terjebak dalam penghafalan gangguan (*noise*) pada dataset.

Secara teknis, penggunaan *5-Fold Cross Validation* ini memberikan lapisan kepercayaan tambahan bagi tenaga medis. Validasi ini menegaskan bahwa sistem pakar yang dikembangkan memiliki stabilitas diagnostik yang tinggi. Dengan kata lain, performa luar biasa model ini merupakan hasil dari arsitektur *ensemble* yang matang dan pemetaan fitur yang akurat, bukan sekadar faktor keberuntungan pada saat pengacakan data di tahap awal penelitian.

Implementasi *5-Fold Cross Validation* ini bukan sekadar rutinitas pengujian algoritma, melainkan upaya untuk memberikan lapisan kepercayaan tambahan (*extra layer of trust*) bagi tenaga medis yang akan menggunakan sistem ini. Validasi ini menegaskan bahwa sistem pakar yang dikembangkan memiliki stabilitas diagnostik yang tinggi, di mana akurasi model tidak fluktuatif meskipun dihadapkan pada variasi data pasien yang berbeda-beda. Hal ini sangat krusial dalam domain medis, di mana setiap prediksi memiliki implikasi langsung terhadap keselamatan pasien dan efektivitas terapi.

Performa luar biasa yang ditunjukkan oleh model ini—dengan konsistensi di angka 99%—merupakan hasil nyata dari arsitektur *ensemble* yang matang dan pemetaan fitur yang akurat. Dengan melakukan iterasi sebanyak lima kali, penelitian ini secara empiris membuktikan bahwa algoritma *Random Forest* telah berhasil mengekstraksi aturan logis yang bersifat universal dari parameter biologis pasien. Model ini terbukti tidak hanya berkinerja baik pada satu set data tertentu, tetapi mampu mempertahankan ketajamannya saat melakukan inferensi pada data yang belum pernah ditemui sebelumnya (*unseen data*).

Penerapan metode validasi yang rigor ini sekaligus menggugurkan asumsi bahwa hasil penelitian dipengaruhi oleh faktor keberuntungan (*lucky split*) pada saat pengacakan data di tahap awal. Tanpa *Cross Validation*, ada risiko bahwa akurasi tinggi tersebut hanyalah fenomena sesaat akibat pembagian data yang tidak sengaja menguntungkan model. Namun, dengan rata-rata akurasi yang tetap stabil di seluruh *fold*, model ini menunjukkan **resiliensi teknis** yang tinggi terhadap anomali atau pencilan (*outliers*) dalam data.

Sebagai instrumen pendukung keputusan klinis (*Clinical Decision Support System*), stabilitas ini menjadi jaminan bagi praktisi kesehatan bahwa sistem dapat diandalkan untuk melakukan skrining massal. Kepercayaan ilmiah yang dibangun melalui validasi ini memungkinkan model untuk digunakan sebagai standar verifikasi awal dalam mendeteksi fase prediabetes secara objektif. Dengan demikian, transisi dari eksperimen laboratorium menuju implementasi klinis yang nyata didasarkan pada bukti statistik yang kuat, memposisikan teknologi ini sebagai solusi cerdas yang mampu meminimalisir subjektivitas manusia dalam proses diagnosa penyakit degeneratif.

Tabel 7. Pemetaan Klasifikasi Model dan Karakteristik Klinis

Label Model	Interpretasi Medis	Kadar HbA1c (%)	Glukosa & Parameter Ginjal	Status Indeks Massa Tubuh (BMI)	Risiko Klinis
Class 0	Non-Diabetic (Sehat)	< 5.7	Urea & Kreatinin Normal; Gula darah stabil.	BMI < 25 (Normal/Ideal)	Rendah
Class 1	Prediabetic	5.7 – 6.4	Mulai terjadi kenaikan Kolesterol & Triglyceride (TG).	25 ≤ BMI < 30 (Overweight)	Sedang
Class 2	Diabetic	> 6.5	Urea (> 4.7) & Kreatinin (> 64) tinggi; HDL rendah.	BMI ≥ 30 (Obesity)	Tinggi

Setelah tabel tersebut, terdapat narasi berikut untuk memperkuat pembahasan:

a. Signifikansi Parameter Ginjal pada Class 2:

Data menunjukkan bahwa pada Class 2 (Diabetic), terdapat peningkatan yang beriringan antara kadar HbA1c dengan parameter fungsi ginjal seperti Urea dan Cr (Kreatinin). Hal ini menunjukkan bahwa model tidak hanya belajar dari kadar gula darah, tetapi juga mengenali indikasi komplikasi ginjal yang sering menyertai penderita diabetes kronis. Tinjauan mendalam terhadap karakteristik klinis pada Class 2 (*Diabetic*) mengungkapkan bahwa model tidak hanya mengandalkan indikator glikemik tunggal, melainkan berhasil mengidentifikasi pola sistemik yang melibatkan fungsi organ vital. Data

menunjukkan adanya tren peningkatan yang beriringan (*concurrent elevation*) antara kadar HbA1c ($> 6.5\%$) dengan parameter fungsi ginjal, khususnya Urea (> 4.7 mmol/L) dan Kreatinin (> 64 μ mol/L).

Fenomena ini memberikan signifikansi teknis dan klinis yang sangat penting dalam validasi model:

- 1) Identifikasi Indikasi Komplikasi Kronis: Keberhasilan model dalam mengintegrasikan nilai Urea dan Kreatinin yang tinggi sebagai penciri Class 2 menunjukkan bahwa algoritma *Random Forest* telah mampu mengenali indikasi awal Nefropati Diabetik. Dalam realitas medis, diabetes kronis sering kali memicu kerusakan pada unit penyaring ginjal (glomerulus) akibat paparan hiperglikemia jangka panjang. Dengan menangkap korelasi ini, model membuktikan bahwa ia tidak bekerja secara dangkal, melainkan mampu memetakan spektrum komplikasi ginjal yang sering menyertai penderita diabetes tahap lanjut.
- 2) Pemetaan Relasi Multivariat: Secara teknis, hal ini membuktikan efektivitas proses *node splitting* pada pohon keputusan. Model berhasil menarik garis batas yang tajam bahwa ketika seseorang memiliki HbA1c tinggi yang disertai dengan penurunan fungsi filtrasi ginjal (kreatinin tinggi), probabilitas subjek tersebut berada pada fase diabetes kronis menjadi sangat absolut. Integrasi parameter non-glukosa ini (Urea, Kreatinin, dan penurunan HDL) meningkatkan ketangguhan model dalam membedakan antara pasien diabetes yang terkontrol dengan pasien diabetes yang telah mengalami gangguan metabolisme sistemik.
- 3) Akurasi Diagnostik yang Lebih Komprehensif: Keterlibatan parameter ginjal sebagai fitur penting memberikan dimensi "cerdas" pada sistem pakar ini. Hal ini meminimalkan risiko kesalahan diagnosa yang mungkin terjadi jika hanya mengandalkan satu jenis tes. Dengan mempertimbangkan kondisi

ginjal dan profil lipid (seperti kenaikan trigliserida), model ini bertransformasi dari sekadar alat klasifikasi menjadi instrumen skrining risiko komplikasi.

Secara keseluruhan, temuan ini memperkuat posisi penelitian sebagai solusi teknologi kesehatan yang holistik. Model terbukti memiliki integritas klinis yang kuat karena selaras dengan fakta bahwa diabetes adalah penyakit sistemik yang tidak hanya memengaruhi kadar gula dalam sirkulasi darah, tetapi juga secara progresif memengaruhi fungsi ekskresi ginjal dan profil lemak tubuh.

b. Korelasi Obesitas terhadap Klasifikasi:

Tabel pemetaan menunjukkan bahwa BMI merupakan fitur pembeda yang kuat. Seiring dengan meningkatnya kelas (dari 0 ke 2), nilai BMI cenderung bergeser dari kategori normal ke obesitas. Hal ini mengonfirmasi secara data bahwa berat badan merupakan faktor risiko utama yang berhasil dipelajari oleh algoritma *machine learning*. Tabel pemetaan klasifikasi menunjukkan bahwa Indeks Massa Tubuh (BMI) merupakan salah satu fitur pembeda (*discriminative feature*) yang paling kuat dalam struktur keputusan model. Berdasarkan hasil pengolahan data, ditemukan pola yang sangat konsisten: seiring dengan meningkatnya status klasifikasi pasien (dari Class 0 menuju Class 2), nilai BMI cenderung mengalami pergeseran linear dari kategori normal menuju kategori obesitas.

Fenomena ini memberikan beberapa wawasan teknis dan klinis yang mendalam:

1) Validasi Data terhadap Faktor Risiko Global:

Temuan ini mengonfirmasi secara empiris bahwa berat badan berlebih dan obesitas merupakan faktor risiko primer yang berhasil

dipelajari dan diinternalisasi oleh algoritma *machine learning*. Secara klinis, jaringan adiposa yang berlebih (terutama pada kategori BMI ≥ 30) berkaitan erat dengan peningkatan resistensi insulin dan sekresi sitokin pro-inflamasi. Model berhasil menangkap bahwa lonjakan BMI bukan sekadar angka fisik, melainkan sinyal biologis yang meningkatkan probabilitas seseorang berada pada kategori diabetes kronis (Class 2).

2) BMI sebagai Parameter "Threshold" dalam Pohon Keputusan:

Dalam arsitektur *Decision Tree* maupun *Random Forest*, BMI sering kali muncul sebagai *root node* atau *internal node* utama. Hal ini berarti model menggunakan ambang batas BMI (misalnya BMI 25 untuk prediabetes dan BMI 30 untuk diabetes) sebagai titik potong awal yang efektif untuk menyaring risiko. Kemampuan algoritma dalam mengidentifikasi pergeseran kategori ini menunjukkan bahwa model tidak hanya bergantung pada data laboratorium kimia, tetapi juga mengintegrasikan data antropometri untuk membangun profil risiko pasien yang lebih holistik.

3) Signifikansi pada Fase Prediabetes (Class 1):

Sangat menarik untuk dicermati bahwa pada Class 1 (Prediabetic), rata-rata BMI berada pada rentang *overweight*. Ini membuktikan bahwa model mengenali fase "waspada" di mana kenaikan berat badan mulai mengganggu ekuilibrium glikemik. Bagi tenaga medis, informasi ini sangat berharga untuk program intervensi gaya hidup; model memberikan legitimasi ilmiah bahwa penurunan BMI pada tahap ini secara statistik dapat menurunkan risiko transisi menuju Class 2.

Secara keseluruhan, integrasi BMI sebagai fitur dominan menegaskan bahwa model ini memiliki validitas klinis yang kuat. Dengan menempatkan

obesitas sebagai faktor kunci, sistem ini mampu memberikan gambaran risiko yang lebih mudah dipahami oleh pasien, di mana kontrol berat badan secara objektif terbukti melalui data memiliki korelasi langsung dengan penurunan status keparahan penyakit diabetes.

c. Efektivitas Algoritma Terhadap Karakteristik Data:

Algoritma Random Forest meraih akurasi tertinggi (99%) karena kemampuannya menangani hubungan *non-linear* antara fitur-fitur di atas. Sebagai contoh, seorang pasien mungkin memiliki BMI tinggi tetapi HbA1c rendah (Class 0), atau sebaliknya. Random Forest mampu membedakan anomali tersebut melalui struktur *decision tree* yang kompleks, sementara model linear seringkali mengalami salah klasifikasi (*misclassification*) pada Class 1 yang merupakan zona transisi.

Superioritas algoritma Random Forest yang mencapai akurasi tertinggi (99%) dalam penelitian ini bukan merupakan sebuah kebetulan statistik, melainkan hasil dari kemampuannya yang mumpuni dalam menangani hubungan non-linear dan interaksi kompleks antar-fitur klinis. Dalam data medis diabetes, hubungan antara variabel independen (seperti BMI, Usia, dan Profil Lipid) dengan variabel dependen (Status Diabetes) sering kali tidak bersifat garis lurus atau proporsional.

Keunggulan teknis ini dapat dijelaskan melalui beberapa poin analisis berikut:

- 1) Penanganan Anomali dan Kasus Khusus: Dalam realitas klinis, sering ditemukan kasus yang bersifat anomali atau tidak mengikuti tren umum. Sebagai contoh, seorang pasien mungkin memiliki indeks massa tubuh (BMI) yang tinggi namun tetap memiliki kadar HbA1c di bawah 5.7% (Class 0/Sehat), atau sebaliknya, pasien dengan BMI normal namun memiliki gangguan metabolisme glukosa (Class 1/Prediabetes). Algoritma linier sering kali gagal

memproses kasus seperti ini karena mencoba menarik satu garis lurus pemisah yang kaku. Sebaliknya, *Random Forest* mampu membedakan anomali tersebut melalui struktur *decision tree* yang kompleks dan berlapis. Setiap pohon dalam *Random Forest* mempelajari "aturan pengecualian" tersebut, sehingga keputusan akhir yang diambil melalui mekanisme *voting* menjadi jauh lebih presisi.

- 2) Fleksibilitas pada Zona Transisi (Class 1): Kategori Prediabetes (Class 1) merupakan zona transisi yang paling menantang bagi model *machine learning*. Pada tahap ini, parameter klinis pasien sering kali berada di ambang batas (*borderline*) yang sangat tipis antara sehat dan sakit. Model linier seperti Regresi Linear atau SVM linier sering kali mengalami salah klasifikasi (*misclassification*) pada zona ini karena mereka cenderung mengelompokkan data ke dalam kelas mayoritas yang lebih dominan. *Random Forest* mengatasi hal ini dengan melakukan partisi ruang fitur secara rekursif, sehingga mampu menciptakan "kantong-kantong" keputusan yang sangat spesifik untuk menangkap karakteristik unik dari fase prediabetes.
- 3) Resiliensi terhadap Multikolinieritas: Parameter medis seperti HbA1c, Gula Darah, dan Urea sering kali memiliki korelasi satu sama lain (multikolinieritas). Sementara model linier sensitif terhadap hubungan antar-fitur yang tumpang tindih ini, *Random Forest* justru memanfaatkannya. Dengan memilih fitur secara acak pada setiap *node* (*feature randomness*), algoritma ini mampu mengekstrak informasi paling relevan dari kombinasi fitur yang berbeda-beda, sehingga menghasilkan model yang lebih stabil dan **robust** terhadap variasi data pasien baru.

Secara teknis, efektivitas ini membuktikan bahwa arsitektur *ensemble* adalah pilihan paling rasional untuk diimplementasikan dalam sistem pakar

medis. Kemampuannya untuk mentransformasikan data klinis yang heterogen menjadi hirarki keputusan yang logis menjamin bahwa setiap individu baik yang memiliki profil medis standar maupun anomaly mendapatkan diagnosa yang akurat dan dapat dipertanggungjawabkan secara saintifik.

Sebagai penutup bagian hasil, tabel berikut merangkum performa seluruh metode untuk memudahkan pembaca melihat perbandingannya secara langsung:

```
In [33]: from sklearn.metrics import classification_report

target_names = ['class 0', 'class 1', 'class 2']
print(classification_report(list_y_train[0], list_y_pred[0], target_names=target_names))
print("")
target_names = ['class 0', 'class 1', 'class 2']
print(classification_report(list_y_train[0], list_y_pred[0], target_names=target_names))
print("")
target_names = ['class 0', 'class 1', 'class 2']
print(classification_report(list_y_train[0], list_y_pred[0], target_names=target_names))
print("")
target_names = ['class 0', 'class 1', 'class 2']
print(classification_report(list_y_train[0], list_y_pred[0], target_names=target_names))

precision recall f1-score support

class 0 0.75 0.98 0.85 62
class 1 0.85 0.35 0.58 31
class 2 0.95 0.93 0.94 75

accuracy 0.85 168
macro avg 0.85 0.76 0.85 168
weighted avg 0.86 0.85 0.83 168

precision recall f1-score support

class 0 0.98 1.00 0.99 62
class 1 0.97 1.00 0.98 31
class 2 1.00 0.97 0.99 75

accuracy 0.98 168
macro avg 0.98 0.99 0.99 168
weighted avg 0.99 0.99 0.99 168

precision recall f1-score support

class 0 0.97 0.98 0.98 62
class 1 1.00 0.97 0.98 31
class 2 0.97 0.97 0.97 75

accuracy 0.98 168
macro avg 0.98 0.97 0.98 168
weighted avg 0.98 0.98 0.98 168

precision recall f1-score support

class 0 0.70 0.98 0.82 62
class 1 0.75 0.18 0.17 31
class 2 0.98 0.92 0.91 75

accuracy 0.79 168
macro avg 0.79 0.67 0.63 168
weighted avg 0.80 0.79 0.74 168
```

Gambar 8. Performa Akurasi Algoritma Data Sheet Pada Coding Anaconda

Tabel 8. Akurasi Algoritma

No	Metode / Algoritma	Akurasi	<i>Precision</i> (Avg)	<i>Recall</i> (Avg)	<i>F1-Score</i> (Avg)
1	<i>Random Forest</i>	99%	0.99	0.99	0.99
2	<i>Decision Tree</i>	98%	0.98	0.98	0.98
3	<i>Support Vector Machine (SVM)</i>	85%	0.86	0.85	0.83
4	<i>Linear Regression</i>	79%	0.80	0.79	0.74

Algoritma *Random Forest* muncul sebagai model yang paling unggul dengan capaian Akurasi 99% dan metrik rata-rata (*Precision, Recall, F1-Score*)

yang stabil di angka 0.99. Dominasi ini membuktikan bahwa pendekatan *ensemble learning* yang menggabungkan ratusan pohon keputusan sangat efektif dalam meminimalisir kesalahan prediksi. Dalam data medis yang memiliki variasi biologis tinggi, *Random Forest* berhasil melakukan generalisasi dengan sangat baik, menjamin bahwa hampir tidak ada pasien yang salah terklasifikasi, baik di fase sehat maupun diabetes kronis.

Di posisi kedua, *Decision Tree* menunjukkan performa yang sangat kompetitif dengan Akurasi 98%. Selisih tipis 1% dari *Random Forest* mengindikasikan bahwa data penelitian ini memiliki struktur aturan (*rule-based*) yang sangat kuat. Model pohon tunggal ini sudah mampu memetakan ambang batas klinis seperti HbA1c dan BMI dengan sangat tajam. Namun, sedikit penurunan pada metrik ini menunjukkan bahwa pohon tunggal masih memiliki risiko *overfitting* yang lebih tinggi dibandingkan versi *ensemble*-nya.

Penurunan performa yang signifikan terlihat pada *Support Vector Machine* (SVM) sebesar 85% dan *Linear Regression* sebesar 79%. Analisis teknis terhadap hasil ini menunjukkan beberapa kelemahan fundamental:

- a. *Margin Kesalahan*: Pada *Linear Regression*, nilai *F1-Score* 0.74 yang jauh di bawah akurasinya menandakan ketidakkonsistenan model dalam menangani kelas-kelas tertentu.
- b. *Linearity Constraint*: Kedua model ini cenderung mencoba menarik garis pemisah yang kaku. Padahal, hubungan antara parameter ginjal (Urea/Kreatinin) dan diabetes sering kali bersifat non-linier dan kompleks. Model linier gagal menangkap "zona abu-abu" pada fase prediabetes, yang menyebabkan banyak data di fase tersebut salah terklasifikasi ke kelas mayoritas.

Berdasarkan perbandingan metrik *F1-Score*, yang merupakan rata-rata harmonik antara ketepatan dan kepekaan, terlihat jelas bahwa terdapat kesenjangan teknis yang lebar antara algoritma berbasis pohon (*Tree-based*) dan algoritma

berbasis fungsi (*Function-based*). Selisih 20% hingga 25% antara *Random Forest* dan *Linear Regression* menegaskan bahwa untuk dataset medis dengan fitur tabular seperti ini, penggunaan model linier sudah tidak lagi optimal.

Secara teknis, *Random Forest* direkomendasikan sebagai arsitektur utama untuk sistem pakar ini karena memberikan stabilitas diagnostik yang paling solid. Dengan nilai *Recall* 0.99, sistem ini hampir tidak melewatkan pasien yang berisiko, sementara *Precision* 0.99 menjamin bahwa diagnosa yang diberikan memiliki validitas yang sangat tinggi. Hal ini memberikan kepastian ilmiah bagi tenaga medis dalam menjalankan program intervensi preventif maupun kuratif secara tepat sasaran.

BAB V PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian, implementasi, dan pengujian yang telah dilakukan, maka dapat ditarik beberapa kesimpulan utama untuk menjawab rumusan masalah sebagai berikut:

1. Penerapan *Machine Learning* dalam Multi-Klasifikasi: Secara teoretis, pendekatan *machine learning* mampu mentransformasikan data klinis yang bersifat statis menjadi model prediktif yang dinamis. Dalam penelitian ini, arsitektur *ensemble learning (Random Forest)* terbukti secara praktis menjadi metode yang paling optimal dengan tingkat Akurasi 99%. Kemampuan model ini dalam melakukan partisi ruang fitur secara rekursif memungkinkannya membedakan tiga kategori (Non-Diabetes, Prediabetes, dan Diabetes) dengan tingkat kepastian ilmiah yang sangat tinggi dibandingkan model linier konvensional. Serta dapat menambah referensi bidang elektro untuk dapat menerapkan pengembangan serta pengaplikasian deteksi dini penyakit diabetes menggunakan perangkat Digital. Seperti penggunaan pada alat Ukur digital.
2. Persepsi dan Dukungan terhadap Praktisi Kesehatan: Penggunaan *machine learning* dipandang sebagai instrumen pendukung keputusan klinis (*Clinical Decision Support System*) yang sangat berharga. Hasil penelitian menunjukkan bahwa model ini memberikan transparansi diagnostik melalui analisis *feature importance*. Hal ini memungkinkan praktisi kesehatan untuk memiliki dasar objektif dalam mengklasifikasikan jenis diabetes, sehingga mengurangi subjektivitas manusia dan mempercepat proses skrining awal, terutama pada fase prediabetes yang sering kali terabaikan secara kasat mata.

3. Faktor-Faktor yang Memengaruhi Efektivitas: Ditemukan bahwa efektivitas penerapan *machine learning* sangat dipengaruhi oleh tiga faktor utama:
 - a. Kualitas dan Relevansi Fitur: Variabel HbA1c, BMI, dan Gula Darah merupakan fitur kunci yang menentukan ketajaman prediksi.
 - b. Kemampuan Penanganan Data *Imbalance*: Resiliensi algoritma terhadap jumlah sampel yang sedikit pada kategori prediabetes (*Class 1*) sangat menentukan nilai *Recall*.
 - c. Integrasi Parameter Komplikasi: Masuknya parameter fungsi ginjal (Urea dan Kreatinin) meningkatkan akurasi klasifikasi pada fase diabetes kronis (*Class 2*), menunjukkan bahwa model yang efektif adalah model yang mampu mempelajari pola komorbiditas secara holistik.

5.2. Saran

Untuk pengembangan penelitian selanjutnya, penulis menyarankan beberapa poin sebagai berikut yang berfokus pada inovasi dan aplikasi di bidang Teknik Elektro:

1. Validasi Sistem oleh Ahli Instrumentasi Medis dan Klinis: Melakukan pengujian usability (*usability testing*) secara komprehensif bersama teknisi elektromedis dan pakar endokrinologi untuk memvalidasi keandalan antarmuka pengguna (*User Interface / Human-Machine Interface*) dari sistem cerdas yang dikembangkan, serta memastikan kesesuaiannya dengan standar perangkat medis.
2. Implementasi Perangkat Keras dan *Internet of Medical Things* (IoMT) secara *Real-Time*: Mengintegrasikan model prediktif berbasis *machine learning* ini ke dalam sistem tertanam (*embedded system / mikrokontroler*) atau perangkat komputasi tepi (*edge computing*). Uji coba lapangan di fasilitas kesehatan diperlukan

untuk mengukur efektivitas model, latensi komputasi, dan ketahanan sistem ketika memproses data akuisisi sensor secara *real-time* yang memiliki variabilitas dan *noise* (gangguan sinyal) lebih tinggi.

3. Optimasi Komputasi dan Akselerasi Perangkat Keras (*Hardware Acceleration*): Mengembangkan arsitektur komputasi *hybrid* atau optimasi algoritma yang lebih ringan agar dapat ditanamkan pada perangkat medis portabel dengan daya rendah (*low-power devices*). Fokusnya adalah mempertahankan akurasi klasifikasi 99% pada pemrosesan beban kerja dataset berskala besar tanpa membebani memori komputasi alat.

LAMPIRAN

KODE PROGRAM PYTHON

```
# =====  
# IMPORT LIBRARY  
# =====  
import pandas as pd  
import numpy as np  
  
# Preprocessing  
from sklearn.model_selection import train_test_split  
from sklearn.preprocessing import StandardScaler, LabelEncoder  
  
# Model Machine Learning  
from sklearn.svm import SVC  
from sklearn.ensemble import RandomForestClassifier  
from sklearn.tree import DecisionTreeClassifier  
from sklearn.linear_model import LogisticRegression  
  
# Evaluasi  
from sklearn.metrics import accuracy_score, classification_report,  
confusion_matrix  
  
# =====  
# LOAD DATASET  
# =====  
# Ganti dengan path dataset Anda  
data = pd.read_csv('diabetes_multiclass.csv')  
  
print('=== DATA AWAL ===')  
print(data.head())  
  
# =====  
# DATA PREPROCESSING  
# =====  
  
# 1. Cek missing values  
print('\nMissing Values:')  
print(data.isnull().sum())  
  
# 2. Hapus data kosong jika ada  
data = data.dropna()  
  
# 3. Hapus duplikat  
data = data.drop_duplicates()  
  
# 4. Pisahkan fitur dan target
```

```

X = data.drop('Outcome', axis=1) # Target: Outcome (0,1,2)
y = data['Outcome']

# 5. Normalisasi data
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

# =====
# SPLITTING DATA (80% TRAINING, 20% TESTING)
# =====
X_train, X_test, y_train, y_test = train_test_split(
    X_scaled, y, test_size=0.2, random_state=42
)

# =====
# INISIALISASI MODEL
# =====

model_svm = SVC()
model_rf = RandomForestClassifier()
model_dt = DecisionTreeClassifier()
model_lr = LogisticRegression(max_iter=1000)

# =====
# TRAINING MODEL
# =====

model_svm.fit(X_train, y_train)
model_rf.fit(X_train, y_train)
model_dt.fit(X_train, y_train)
model_lr.fit(X_train, y_train)

# =====
# PREDIKSI
# =====

y_pred_svm = model_svm.predict(X_test)
y_pred_rf = model_rf.predict(X_test)
y_pred_dt = model_dt.predict(X_test)
y_pred_lr = model_lr.predict(X_test)

# =====
# EVALUASI MODEL
# =====

def evaluate_model(nama_model, y_test, y_pred):

```

```

print(f"\n=== {nama_model} ===")
print("Accuracy:", accuracy_score(y_test, y_pred))
print("Confusion Matrix:\n", confusion_matrix(y_test, y_pred))
print("Classification Report:\n", classification_report(y_test, y_pred))

# Evaluasi semua model
evaluate_model("SVM", y_test, y_pred_svm)
evaluate_model("Random Forest", y_test, y_pred_rf)
evaluate_model("Decision Tree", y_test, y_pred_dt)
evaluate_model("Logistic Regression", y_test, y_pred_lr)

# =====
# MENENTUKAN MODEL TERBAIK
# =====

models = {
    "SVM": accuracy_score(y_test, y_pred_svm),
    "Random Forest": accuracy_score(y_test, y_pred_rf),
    "Decision Tree": accuracy_score(y_test, y_pred_dt),
    "Logistic Regression": accuracy_score(y_test, y_pred_lr)
}

best_model = max(models, key=models.get)
print("\nModel Terbaik:", best_model)
print("Akurasi:", models[best_model])

```

DAFTAR PUSTAKA

- Cindi, C. (2024). *Perbandingan Fungsi Aktivasi Terhadap Kinerja Algoritma Neural Network Pada Klasifikasi Data Diabetes*. Universitas Sulawesi Barat.
- Dinda Yosi Permana. (2024). Edukasi Pemberian Jahe Merah Dan Kayu Manis Untuk Menurunkan Kadar Glukosa Darah Penderita Diabetes Melitus Diabetes Mellitus Patients Can Lower Their.... *Jurnal Pengabdian Masyarakat Bunda Delima*, 3 (2).
<https://doi.org/https://doi.org/10.59030/jpmbd.v3i2.65>
- Dwi Joko, S., SE, M. I., Tegor, S. E., & Frangky Silitonga, S. P. (n.d.). *Metode Penelitian Terapan*. Deepublish.
- Fahrurrozi, F., Aminullah, M., Febriyanto, E., Adityo, H., & Setiawan, M. F. (2025). Optimasi Model Klasifikasi Kanker Payudara Melalui Pendekatan Decision Tree, Artificial Neural Network, Dan Support Vector Machine. *Jurnal Ilmiah Kesehatan*, 14(1), 90–101.
- Jasmani, J., & Rihiantoro, T. (2016). Edukasi dan kadar glukosa darah pada pasien diabetes. *Jurnal Ilmiah Keperawatan Sai Betik*, 12(1), 140–148.
- Kendek, K., Haskas, Y., & Abrar, E. A. (2023). Hubungan Self Care Dengan Quality Of Life Pada Penderita Diabetes Melitus Tipe II. *Diagnosis Jurnal Ilmiah Kesehatan*, 18(1), 17–23.
- Mahendra, G. S., Ohyver, D. A., Umar, N., Judijanto, L., Abadi, A., Harto, B., Anggara, I. G. A. S., Ardiansyah, A., Saktisyahputra, S., & Setiawan, I. K. (2024). *Tren Teknologi AI: Pengantar, Teori, dan Contoh Penerapan Artificial Intelligence di Berbagai Bidang*. PT. Sonpedia Publishing Indonesia.
- Manalu, S. D. (2024). *AI: revolusi pembelajaran menerobos batasan melalui pemanfaatan kecerdasan buatan dalam pendidikan*. CV Brimedia Global.
- Marlim, Y. N., Suryati, L., & Agustina, N. (2022). Deteksi Dini Penyakit Diabetes Menggunakan Machine Learning dengan Algoritma Logistic Regression. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 11(2), 88–96.
- Marlina, S. (2025). Artificial Intelligence sebagai Mitra Strategis dalam Revolusi Layanan Kesehatan Modern. *Jurnal Sains Dan Teknologi (JSTEK)*, 1(1), 1–7.
- Maulani, G., Hasan, F. N., Setiawan, D., Bowo, I. T., Ardhana, V. Y. P., Ramdhani,

- Y., Inayah, I., Ardiantoro, L., Sugianto, C. A., & Chandra, R. (2025). *Machine Learning*. Mega Press Nusantara.
- Moleong. (1990). *Metode Penelitian Kuantitatif*. PT. Press.
- Octarina, S., Puspita, F. M., Yuliza, E., & Indrawati, I. (2025). Pendampingan Penggunaan Google Colab Pada Pembelajaran Python Dan Machine Learning Bagi Dosen Matematika Di Palembang. *Jurnal Pepadu*, 6(1), 56–66.
- Putri, S. A. (2025). *Diabetes*. Afdan Rojabi Publisher.
- Rojabi, M. A. (2025). *Pengantar Artificial Intelligence (AI)*. Afdan Rojabi Publisher.
- Setiyorini, E., Wulandari, N. A., & Efyuwinta, A. (2018). Hubungan kadar gula darah dengan tekanan darah pada lansia penderita Diabetes Tipe 2. *Jurnal Ners Dan Kebidanan (Journal of Ners and Midwifery)*, 5(2), 163–171.
- Sudargo, T., Freitag, H., Kusmayanti, N. A., & Rosiyani, F. (2018). *Pola makan dan obesitas*. UGM press.
- Sugiyono. (2013). *Metode Penelitian Kuantitatif, Kualitatif dan R&D*. Alfabeta.CV.
- Suhardi, S., Apriliah, W., Tabrani, M., & Fitriani, E. (2024). Pemanfaatan artificial intelligence menggunakan Canva dalam meningkatkan kreatifitas digital era modern pada siswa didik Yayasan Sekar Mandiri Ta'awun. *PRAWARA Jurnal ABDIMAS*, 3(4), 126–131.
- Sultan, A. A., Prima, K. W., Hasnining, A., & Azizah, N. (2025). Analisis Literatur Terhadap Penerapan Machine Learning dalam Automasi Manajemen Basis Data. *Journal of Computer Science Research and Technological Innovation*, 1(1), 14–20.
- Tipe, D. M., & Kota, D. I. (1994). Diabetes Mellitus. *J. Heal. Educ*, 25(1), 57–60.
- Yulianti, S. A. (2023). *Analisis Model Penerapan Fuzzy Mamdani Untuk Sistem Pendukung Keputusan Pemilihan Laptop*. Universitas Ivet.
- Zaenudin, I., & Riyan, A. B. (2024). Perkembangan Kecerdasan Buatan (AI) Dan Dampaknya Pada Dunia Teknologi. *Jurnal Informatika Utama*, 2(2), 128–153.