

Implementasi Model *Artificial Neural Network* (ANN) Untuk Prediksi Penyakit Diabetes Melitus Tipe 2

1st Ananda Fikri Satriyo Hastomo
Teknik Informatika

Universitas Telkom Purwokerto
Purwokerto, Indonesia
anandafikrisatriyo@student.telkomuniversity.ac.id

2nd Ipam Fuaddina Adam
Teknik Informatika

Universitas Telkom Purwokerto
Purwokerto, Indonesia
ipamya@telkomuniversity.ac.id

3rd Muhammad Raafi'u Firmansyah
Teknik Informatika

Universitas Telkom Purwokerto
Purwokerto, Indonesia
raafiu@telkomuniversity.ac.id

Abstrak — Diabetes Melitus (DM) tipe 2 adalah penyakit kronis dengan prevalensi global yang terus melonjak, deteksi dini perlu dilakukan untuk menghindari komplikasi serius. Tantangan utama dalam membangun model prediktif berbasis data medis adalah ketidakseimbangan kelas yang sering menurunkan sensitivitas model. Riset ini bertujuan mengevaluasi model ANN untuk mengatasi data yang tidak seimbang dan *hyperparameter tuning* guna mengoptimalkan performa pada data rekam medis DM Tipe 2. Pendekatan hybrid yang mengintegrasikan *Artificial Neural Network* (ANN) dengan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) untuk mengatasi *imbalanced data*, serta optimalisasi *hyperparameter* melalui *Randomized Search*. *Dataset* bersumber dari Mendeley data yang diambil dari data rekam medis pasien di Medical City Hospital, Irak, meliputi variabel klinis seperti HbA1C, indeks massa tubuh (BMI), dan profil lipid. Evaluasi dilakukan dalam empat skenario untuk mengukur dampak masing-masing komponen terhadap performa model. Hasil menunjukkan bahwa kombinasi SMOTE dan algoritma ANN secara signifikan meningkatkan akurasi dan *recall*, dengan model terbaik (skenario ke-2) mencapai akurasi 97,50% dan *recall* 89,96%. Pendekatan algoritma ANN mampu terbukti efektif dalam meningkatkan keandalan prediksi DM tipe 2, untuk mendukung pengembangan sistem deteksi dini berbasis kecerdasan buatan.

Kata kunci— Diabetes melitus tipe 2, *Artificial Neural Network*, SMOTE, *Imbalanced data*, *Hyperparameter tuning*

I. PENDAHULUAN

Perubahan pola penyakit global dalam beberapa dekade terakhir mengalami pergeseran yang signifikan dari dominasi penyakit menular menuju penyakit tidak menular atau *Non-Communicable Diseases* (NCD). Pada tahun 2021, prevalensi penyakit tidak menular dilaporkan mencapai lebih dari 91.000 kasus per 100.000 penduduk. Meskipun angka kematian akibat NCD mengalami penurunan sekitar 27,9% sejak tahun 1990, jumlah individu yang hidup dengan kondisi kronis justru terus meningkat. Di antara berbagai jenis NCD, penyakit diabetes dan penyakit ginjal menunjukkan peningkatan yang cukup signifikan dengan kenaikan sekitar 25,6% dalam periode tersebut [1]. Organisasi *World Health Organization* (WHO) melaporkan bahwa sekitar 41 juta

kematian setiap tahun disebabkan oleh penyakit tidak menular, yang setara dengan sekitar 74% dari total kematian global. Diabetes melitus sendiri diperkirakan berkontribusi terhadap sekitar dua juta kematian setiap tahunnya di seluruh dunia[2].

Di tingkat nasional, data dari *International Diabetes Federation* (IDF) menunjukkan bahwa Indonesia menempati posisi kelima di dunia dengan jumlah penderita diabetes mencapai sekitar 19,47 juta orang, dengan prevalensi sebesar 10,6%. Tingginya angka kejadian tersebut menuntut adanya pendekatan yang lebih efektif dalam upaya deteksi dini, pencegahan komplikasi, serta peningkatan kualitas layanan kesehatan bagi penderita diabetes [3].

Kondisi ini berpotensi menyebabkan komplikasi seperti retinopati diabetik, nefropati, dan neuropati dapat menurunkan kualitas hidup pasien secara signifikan apabila tidak ditangani secara dini. Oleh karena itu, upaya deteksi dini menjadi salah satu strategi penting dalam mengurangi risiko komplikasi jangka panjang [4].

Seiring perkembangan teknologi, pendekatan berbasis *machine learning* mulai banyak diterapkan dalam bidang kesehatan untuk mendukung diagnosis penyakit, termasuk diabetes. *Machine learning* memungkinkan analisis data dalam jumlah besar secara lebih efisien dibandingkan metode konvensional, serta mampu mengidentifikasi pola kompleks yang sulit dideteksi secara manual. Dengan memanfaatkan data medis seperti kadar HbA1c, tekanan darah, indeks massa tubuh (BMI), dan profil lipid, model dapat memprediksi kemungkinan terjadinya diabetes secara lebih akurat [5]. Salah satu metode *deep learning* yang dapat digunakan dalam analisis medis adalah *Artificial Neural Network*, yang mampu mempelajari hubungan antar variabel klinis untuk menghasilkan model yang lebih akurat dibanding metode statistik konvensional.[5].

Berbagai riset terdahulu menunjukkan bahwa penggunaan ANN memiliki potensi yang besar dalam meningkatkan akurasi klasifikasi penyakit diabetes[6]. Model ANN terbukti efektif dalam memproses *dataset* medis baik dalam bentuk data tabular maupun citra medis. Namun demikian, performa model sangat dipengaruhi oleh konfigurasi arsitektur jaringan serta optimasi parameter yang digunakan. Beberapa penelitian menunjukkan bahwa model

ANN dengan arsitektur multi-layer mampu menghasilkan kinerja yang lebih baik dibandingkan model lapisan tunggal, dengan tingkat sensitivitas yang tinggi serta nilai akurasi yang relatif baik [7]. Meskipun demikian, salah satu tantangan utama dalam penerapan *machine learning* pada *dataset* medis adalah masalah ketidakseimbangan data (*imbalanced dataset*), di mana jumlah data pasien sehat sering kali jauh lebih banyak dibandingkan pasien yang benar-benar menderita penyakit. Kondisi ini dapat menyebabkan model cenderung bias terhadap kelas mayoritas sehingga menurunkan kemampuan model dalam mendeteksi kasus penyakit secara akurat[8]. Salah satu pendekatan yang banyak digunakan untuk mengatasi permasalahan tersebut adalah *Synthetic Minority Oversampling Technique* (SMOTE), yang mampu menyeimbangkan distribusi data tanpa menghilangkan karakteristik asli *dataset*[9], [10]. Oleh karena itu, riset ini berfokus pada implementasi model *Artificial Neural Network* untuk prediksi penyakit Diabetes Melitus Tipe 2 dengan menerapkan teknik SMOTE serta proses *hyperparameter tuning* guna mengukur kontribusi masing – masing skenario performa model prediksi yang dihasilkan.

II. KAJIAN TEORI

A. Diabetes Melitus Tipe 2

Diabetes Melitus (DM) merupakan salah satu penyakit metabolik kronis akibat gangguan produksi insulin yang menyebabkan peningkatan kadar glukosa darah. Menurut *American Diabetes Association*, kondisi hiperglikemia kronis pada penderita diabetes dapat menyebabkan kerusakan jangka panjang pada berbagai organ tubuh seperti mata, ginjal, saraf, serta sistem kardiovaskular [11]. Diabetes Melitus Tipe 2 merupakan jenis diabetes yang umum di populasi global dan biasanya berkaitan dengan faktor gaya hidup, seperti pola makan tidak sehat, kurang aktivitas fisik, serta obesitas[11].

B. Machine Learning dalam Bidang Kesehatan

Machine learning memungkinkan sistem belajar dari data untuk membuat prediksi tanpa pemrograman eksplisit. Dalam bidang medis, *machine learning* dimanfaatkan untuk diagnosis penyakit, analisis citra medis, serta prediksi risiko penyakit berdasarkan data klinis, seperti glukosa, IMT, tekanan darah, dan lipid. Proses analisis data medis secara manual membutuhkan waktu lama. *Machine learning* mampu mengolah data besar dan kompleks, sehingga berpotensi menjadi alat pendukung keputusan klinis (*clinical decision support system*) yang meningkatkan kualitas pelayanan kesehatan serta mempercepat proses diagnosis penyakit[12].

C. Deep Learning

Deep learning (DL) adalah segmen dari pembelajaran mesin yang dikembangkan berdasarkan Jaringan Saraf Tiruan (ANN) dengan struktur lapisan yang lebih kompleks, yang memungkinkan pembelajaran representasi data secara bertingkat dari berbagai tingkat abstraksi[13]. Konsepnya terinspirasi dari susunan dan cara kerja otak manusia, khususnya dalam aspek indentifikasi pola dan proses penetapan suatu keputusan[14]. Abstraksi yang tinggi dan rendah secara berjenjang adalah salah satu keunggulan dari *deep learning*, dipadukan dengan kapasitas serta kemampuan

secara otomatis mempelajari representasi dari data [15]. Konsep efisiensi ini membuat unggul dalam menangani data kompleks seperti teks, suara, dan gambar, sehingga *deep learning* dapat berhasil merevolusi ilmu data mining dan penemuan pengetahuan[16].

D. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) merupakan salah satu metode *deep learning* yang terinspirasi dari cara kerja jaringan saraf pada otak manusia, yang tersusun dari *neuron* dalam tiga lapisan utama, yaitu *input layer*, *hidden layer*, dan *output layer*. Setiap *neuron* memproses *input* yang diterima dan menghasilkan *output* berdasarkan bobot dan fungsi aktivasi tertentu [17]. Keunggulan utama ANN adalah kemampuannya dalam mengenali pola yang kompleks dan *non-linier* pada data, menjadikannya efektif untuk berbagai tugas klasifikasi dan prediksi data medis. Dalam konteks diagnosis diabetes, ANN dapat memanfaatkan berbagai variabel klinis seperti kadar HbA1c, tekanan darah, BMI, serta profil lipid untuk mempelajari pola yang berkaitan dengan risiko penyakit [18]. Arsitektur multi-layer terbukti menghasilkan performa lebih baik dibanding jaringan satu lapisan karena mampu mempelajari hubungan yang lebih kompleks antar variabel *input* dan *output* [9], [19].

E. Imbalanced Dataset

Imbalanced dataset merupakan metode representasi pada kondisi distribusi kelas yang mengalami ketidakseimbangan *dataset*, dimana kategori distribusi kelas mayoritas mendominasi dibandingkan dengan kelas minoritas, seperti pada data kelas pra-diabetes. Dalam diagnosis medis, fenomena ini menjadi kendala bagi algoritma pembelajaran mesin yang cenderung bias dalam memprioritaskan akurasi secara global, sehingga mengabaikan kelas minoritas yang memiliki signifikansi yang lebih tinggi dan berpotensi menurunkan tingkat efektivitas model, terutama pada parameter sensitivitas[20].

F. Synthetic Minority Oversampling Technique (SMOTE)

Synthetic Minority Oversampling Technique (SMOTE) merupakan salah satu metode yang banyak digunakan untuk mengatasi permasalahan *imbalanced dataset* dengan menghasilkan data sintesis baru pada kelas minoritas sehingga distribusi data menjadi lebih seimbang [21].

Berbeda dengan metode *oversampling* sederhana yang hanya menduplikasi data, SMOTE menghasilkan sampel baru dengan melakukan interpolasi antara data minoritas yang berdekatan dalam ruang fitur, sehingga variasi data baru yang dihasilkan tetap mempertahankan karakteristik asli dari *dataset* dan meningkatkan kemampuan model dalam mengenali pola pada kelas minoritas [21].

Rumus dari perhitungan teknik SMOTE:

$$Z = P + u * (Q - P) \quad (2.1)$$

Pada persamaan 2.1 menjelaskan rumus dari Teknik SMOTE, dimana:

Z = Data sintesis baru yang dihasilkan

P = Data sampel asli pada kelas minoritas yang dipilih.

u = Angka *random* yang seragam antara 1 dan 0

Q = Salah satu tetangga terdekat dari sampel yang dipilih secara acak.

Dengan menyeimbangkan distribusi data, model *machine learning* dapat belajar secara lebih optimal dan menghasilkan performa klasifikasi yang lebih baik, terutama dalam meningkatkan nilai *recall* dan sensitivitas terhadap kasus penyakit[21].

G. Hyperparameter Tuning

Hyperparameter tuning merupakan proses optimasi parameter pada algoritma *machine learning* yang harus ditentukan sebelum pelatihan dimulai, berbeda dari parameter yang dipelajari oleh model saat training. Dalam algoritma *Artificial Neural Network*, beberapa *hyperparameter* yang sering dioptimasi antara lain jumlah *neuron* pada setiap lapisan, jumlah *hidden layer*, nilai *learning rate*, ukuran batch, serta jumlah *epoch*. Pemilihan kombinasi *hyperparameter* yang tepat dapat memberikan pengaruh yang signifikan terhadap akurasi dan stabilitas model dalam melakukan prediksi [22]. Metode yang lazim digunakan pada proses ini, antara lain *Grid Search*, *Randomized Search*.

H. Penelitian terdahulu

Beberapa riset terdahulu telah mengeksplorasi prediksi diabetes menggunakan pendekatan *machine learning* dan *deep learning*. Aruna Kumari dkk.[23] mengusulkan model *hybrid* menggunakan CNN-LSTM untuk prediksi diabetes yang mampu menangkap pola temporal dalam data pasien, namun model memerlukan sumber daya komputasi tinggi. Berbeda dengan riset tersebut, riset ini menggunakan arsitektur ANN standar yang lebih sederhana namun tetap efisien untuk *dataset* tabular. Selanjutnya, riset oleh Nipa dkk. [24] membahas pengembangan model *machine learning* yang dapat digunakan secara klinis untuk mendeteksi dini diabetes menggunakan *dataset* dari UCI *Machine Learning Repository* dan data primer pasien di Bangladesh. Penelitian tersebut membandingkan berbagai algoritma, dan berhasil mencapai akurasi sebesar 97,11%. Dari kedua riset tersebut, kombinasi ANN dengan SMOTE dan optimasi tuning berpotensi meningkatkan akurasi prediksi diabetes.

III. METODE

A. Subjek dan Objek Penelitian


Subjek dalam riset ini adalah model *Artificial Neural Network* (ANN) yang akan diimplementasikan untuk prediksi penyakit Diabetes Melitus Tipe 2. Model ANN ini menjadi fokus utama pada seluruh rangkaian eksperimen, mulai dari pembangunan arsitektur, penanganan data *imbalanced*, optimasi tuning, hingga evaluasi performa.

Objek dalam riset ini adalah *dataset* dari sumber terbuka data rekam medis masyarakat Irak yang berasal dari mendeley data yang berperan sebagai bahan atau data penelitian yang digunakan untuk melatih dan menguji model ANN, implementasi pengaruh penerapan teknik *Synthetic Minority Over Sampling Technique* (SMOTE) terhadap performa model ANN dalam mengatasi *imbalanced* data dari kelas minoritas, pengaruh optimasi *hyperparameter tuning* menggunakan metode *random search* terhadap akurasi model.

B. Diagram Alur Sistem

Riset ini menggunakan *dataset* publik dari Mendeley Data berupa rekam medis masyarakat Irak dan dipublikasikan oleh Ahlam Rashid (2020). *Dataset* terdiri dari 1.000 data

pasien dengan berbagai atribut klinis seperti usia, jenis kelamin, HbA1c, profil lipid, dan indeks massa tubuh yang digunakan untuk mengklasifikasikan tiga kondisi yaitu *Non-Diabetic* (N), *Prediabetic* (P), dan *Diabetic* (Y) [25]. *Dataset* diatas akan diimplementasikan pada model ANN untuk memprediksi penyakit Diabetes Melitus tipe 2 yang akan dibangun. Sebelum masuk ke pemodelan, dilakukan serangkaian pengolahan data yang diagram alur pemodelan ditunjukkan pada Gambar 1.



GAMBAR 1
(Diagram Alir Pemodelan)

Tahap pemodelan diawali dengan *preprocessing data* yang meliputi pembersihan data, penghapusan fitur identitas (Id Pasien dan *No_Patient*), penanganan nilai nol pada menggunakan nilai median, serta *encoding* pada fitur kategorikal seperti Gender dan CLASS agar seluruh data berbentuk numerik. Selanjutnya dilakukan normalisasi menggunakan standarisasi (z-score) untuk menyamakan skala antar fitur. *Dataset* kemudian dibagi menggunakan metode *train-test split* dengan proporsi 80: 20, kemudian diterapkan teknik *Synthetic Minority Oversampling Technique* (SMOTE) pada data pelatihan sehingga distribusi kelas menjadi lebih seimbang. Model prediksi dibangun menggunakan *Artificial Neural Network* (ANN) dengan pendekatan *multilayer perceptron* yang terdiri dari lapisan *input*, *hidden layer* dengan aktivasi ReLU, dan lapisan *output* dengan aktivasi Softmax untuk klasifikasi tiga kelas yaitu *Non-Diabetic* (N), *Prediabetic* (P), dan *Diabetic* (Y). Pada tahap perancangan metodologi, riset ini mengembangkan empat skenario model, seperti yang telah dijelaskan pada tabel 3 bab hasil. Implementasi model dilakukan menggunakan bahasa pemrograman Python dengan pustaka seperti *TensorFlow/Keras*, *scikit-learn*, *imblearn*, serta dilakukan *hyperparameter tuning* menggunakan *random search* untuk memperoleh konfigurasi model terbaik. Evaluasi dilakukan menggunakan data uji dengan metrik evaluasi berupa akurasi, *precision*, *recall*, F1-score, *confusion matrix*, dan AUC-ROC. Kemudian dilakukan analisis untuk membandingkan performa keempat skenario model guna menentukan model ANN terbaik dalam memprediksi Diabetes Melitus tipe 2.

C. Gambaran dan Sumber *dataset* Penyakit DM [25]

Id_pasien	No_pasien	Gender	AGE	Urea	Cr	HbA1C	Chol	TG	HDL	LDL	VLDL	BMI	CLASS
502	17975	F	50	4.7	46	4.9	4.2	0.9	2.4	1.4	0.5	24	N
735	34221	M	26	4.5	62	4.9	3.7	1.4	1.1	2.1	0.6	23	N
420	47973	F	50	4.7	46	4.9	4.2	0.9	2.4	1.4	0.5	24	N
680	87656	F	50	4.7	46	4.9	4.2	0.9	2.4	1.4	0.5	24	N
504	34223	M	33	4.7	46	4.9	4.9	1	0.8	2	0.4	21	N
472	463	M	34	3.9	81	6	6.2	3.9	0.8	3.8	1.8	23	P
85	46300	M	34	3.9	81	6	6.2	3.9	0.8	3.8	1.8	23	P
710	87671	M	34	3.9	81	6	6.2	3.9	1	3.2	1.8	23	P
429	48036	M	31	3.4	55	5.7	4.9	1.6	1	3.2	0.7	24	P
702	87667	M	31	3.4	55	5.7	4.9	1.6	0.9	1.7	0.7	24	P
12	23975	M	31	3	60	12.3	4.1	2.2	0.7	2.4	13.4	37.2	Y
18	23977	M	30	7.1	81	6.7	4.1	1.1	1.2	2.4	8.1	27.4	Y
24	23979	M	45	4.1	63	10.2	4.8	1.3	0.9	3.3	9.5	34.3	Y

GAMBAR 2

(Gambaran dan Sumber *dataset* Penyakit DM)

D. Variabel Penelitian

Penelitian variabel dibagi menjadi variabel *input* dan variabel *output*. Variabel *input* berupa fitur klinis yang digunakan untuk membangun model prediksi, yaitu *Gender*, *AGE*, *Urea*, *Creatine (Cr)*, *HbA1C*, *Cholesterol (Chol)*, *Triglycerides (TG)*, *HDL*, *LDL*, *VLDL*, dan *BMI*. *Dataset* awal juga memuat fitur *Id Pasien* dan *No_Patient*, namun keduanya tidak digunakan dalam pemodelan karena hanya berfungsi sebagai identitas administratif dan tidak memiliki nilai prediktif.

Sementara itu, variabel *output* adalah label kelas yang menunjukkan kondisi diabetes pasien, yaitu *N (Non-Diabetic)*, *P (Prediabetic)*, dan *Y (Diabetic)*. Dengan demikian, penelitian ini merupakan klasifikasi multi-kelas, di mana model *Artificial Neural Network (ANN)* dilatih untuk membedakan ketiga kategori tersebut berdasarkan pola fitur klinis yang digunakan.

E. Skenario Perancangan Model

Riset ini menguji empat skenario *artificial neural network*. Pertama, model dasar tanpa SMOTE dan tuning untuk melihat performa awal. Kedua, SMOTE tanpa tuning untuk menilai pengaruh penyeimbangan kelas. Ketiga, tuning tanpa SMOTE untuk mengukur dampak optimasi parameter. Keempat, kombinasi SMOTE dan tuning dengan *random search* guna mengevaluasi kinerja model secara optimal.

F. Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan *Artificial Neural Network (ANN)* dalam mengklasifikasikan tiga kondisi diabetes, yaitu *Non-Diabetic (N)*, *Prediabetic (P)*, dan *Diabetic (Y)*. Kinerja model dievaluasi menggunakan *matrix* akurasi, *precision*, *recall*, *F1-score*, *AUC*, dan *confusion matrix*. Perhitungan *precision*, *recall*, dan *F1-score* menggunakan *macro averaging* agar setiap kelas memiliki bobot yang sama. *F1-score* makro menjadi metrik utama karena lebih sensitif terhadap ketidakseimbangan kelas, sedangkan *confusion matrix* digunakan untuk melihat pola kesalahan klasifikasi pada masing-masing kelas. Seluruh skenario dievaluasi dengan prosedur yang sama agar perbandingan hasil bersifat objektif dan konsisten.

IV. HASIL DAN PEMBAHASAN

A. Proses *preprocessing* dan pengolahan *dataset*

TABEL 1
(Distribusi kelas sebelum di *resampling*)

Kelas	Jumlah	Persentase
-------	--------	------------

Y (Diabetes)	675	84,38%
N (Normal)	82	10,25%
P (Prediabetes)	43	5,38%
Total	800	100%

Berdasarkan tabel 1, *dataset* riset terdiri dari 12 variabel prediktor dan satu variabel target (*CLASS*) tanpa *missing value*. Distribusi kelas menunjukkan kondisi *imbalanced* dimana kelas Y (*Diabetes*) mendominasi lebih dari 80% data, sedangkan kelas P (*Prediabetes*) memiliki jumlah paling sedikit, sehingga berpotensi menimbulkan bias pada model ANN jika tidak ditangani.


TABEL 2
(Distribusi kelas setelah di *resampling*)

Kelas	Jumlah setelah dilakukan SMOTE
Y (Diabetes)	675
N (Normal)	675
P (Prediabetes)	675
Total	2.025

Berdasarkan tabel 2, setelah diperbaiki hasil proses ini menghasilkan distribusi data yang seimbang pada setiap kelas, dengan masing-masing kelas berjumlah 675 sampel.

Tahapan pra-pemrosesan meliputi penghapusan atribut administratif *Id Pasien* dan *No_Patient*, sehingga *dataset* terdiri dari 12 fitur klinis dan satu variabel target (*CLASS*). Variabel kategorikal *Gender* ke bentuk numerik melalui *encoding*, dan normalisasi seluruh fitur menggunakan *min-max scaling*. *Dataset* kemudian dibagi menjadi 80% data latih dan 20% data uji menggunakan *train_test_split*.

Untuk menangani permasalahan ketidakseimbangan kelas, diterapkan teknik SMOTE pada data latih sehingga distribusi kelas menjadi seimbang dengan 675 sampel dengan total 2.025 sampel. Kondisi ini memungkinkan model mempelajari pola dari masing-masing kelas secara proporsional dan tidak bias. Alur lengkap proses *preprocessing* selanjutnya dapat dilihat pada Gambar 2.



GAMBAR 2

(Alur proses *preprocessing* pemodelan algoritma ANN)


Berdasarkan Gambar 2, memberikan gambaran alur kerja pra-pemrosesan data secara berurutan, mencakup seluruh tahapan transformasi yang diterapkan pada *dataset* hingga siap digunakan dalam pelatihan model *Artificial Neural Network*. Tahapan tersebut bertujuan untuk memastikan *dataset* berada dalam kondisi optimal sehingga dapat digunakan secara efektif dalam proses pelatihan model.

B. Implementasi algoritma *Artificial Neural Network*

Implementasi model *Artificial Neural Network (ANN)* pada penelitian ini dilakukan menggunakan bahasa pemrograman Python dengan pustaka Keras dan *TensorFlow*. Model dirancang untuk melakukan klasifikasi multi-kelas dalam memprediksi tiga kondisi metabolik pasien, yaitu

Normal, Prediabetes, dan Diabetes, dengan fungsi aktivasi softmax pada lapisan keluaran. Arsitektur model dibangun berdasarkan 12 fitur *input* hasil tahap pra-pemrosesan sehingga lapisan *input* terdiri dari 12 neuron. Model dilengkapi dengan dua *hidden layer* menggunakan fungsi aktivasi ReLU untuk menangani pola non-linear, serta dropout untuk mengurangi risiko *overfitting*.

Seluruh arsitektur model diimplementasikan menggunakan API Sequential Keras, dan alur struktur jaringan ditampilkan pada Gambar 3.



GAMBAR 3

(Arsitektur model *Artificial Neural Network* (ANN))

Model *Artificial Neural Network* (ANN) menggunakan fungsi aktivasi softmax pada lapisan keluaran karena tugas klasifikasi melibatkan tiga kelas, yaitu *Non-Diabetic* (N), *Prediabetic* (P), dan *Diabetic* (Y). Proses pelatihan menggunakan fungsi *loss categorical crossentropy* dan optimizor Adam yang mampu melakukan pembaruan parameter secara adaptif. Sebelum pelatihan, label kelas diubah menjadi representasi numerik melalui *one-hot encoding* agar model dapat menghasilkan probabilitas pada tiga *neuron* keluaran. Model dilatih menggunakan 2.025 data latih hasil SMOTE dan divalidasi dengan 200 data uji tanpa *oversampling*. Hasil pelatihan menunjukkan pola konvergensi yang stabil pada nilai loss dan akurasi, yang menandakan bahwa arsitektur ANN yang digunakan telah sesuai dengan karakteristik *dataset* untuk klasifikasi tiga kondisi metabolik.

C. Skenario Eksperimen

Skenario eksperimen dirancang untuk mengevaluasi performa *Artificial Neural Network* (ANN) pada berbagai konfigurasi pengolahan data dan pengaturan pelatihan. Empat skenario digunakan untuk menguji pengaruh pra-pemrosesan data, penerapan SMOTE, konfigurasi arsitektur, dan pengaturan pelatihan terhadap kemampuan model dalam mengklasifikasikan tiga kondisi metabolik pasien, yaitu Normal, Prediabetes, dan Diabetes. Perbedaan utama dari setiap skenario pemodelan ditampilkan pada Tabel 3.

TABEL 3

(Skenario 4 pengujian model)

Kode	Deskripsi Skenario	Karakteristik Utama
M1	ANN tanpa SMOTE	Data asli, ketidakseimbangan kelas dipertahankan, dan proses normalisasi dilakukan.
M2	ANN dan teknik SMOTE	Data latih diseimbangkan menggunakan teknik SMOTE dan pembangunan pada arsitektur dasar model ANN.
M3	ANN dan metode <i>hyperparameter tuning</i>	Parameter seperti <i>epoch</i> , <i>batch size</i> , dan <i>dropout</i> mulai diubah, dan pada proses ini tidak melalui tahapan teknik SMOTE.
M4	Kombinasi algoritma ANN dan teknik SMOTE dan metode <i>hyperparameter tuning</i>	Kombinasi antara teknik SMOTE dan optimasi <i>hyperparameter</i> untuk stabilitas dan generalisasi performa model antar skenario.

D. Hasil Evaluasi Model

Evaluasi dilakukan untuk membandingkan performa empat skenario model *Artificial Neural Network* (ANN) (M1–M4) yang telah dirancang. Setiap model diuji menggunakan 200 data uji tanpa proses SMOTE agar hasil evaluasi mencerminkan kemampuan model dalam melakukan generalisasi pada *dataset* asli. Penilaian kinerja model menggunakan beberapa metrik klasifikasi multi-kelas, yaitu *Accuracy*, *Macro Precision*, *Macro Recall*, *Macro F1-score*, dan *Macro AUC-ROC*. Hasil evaluasi performa keempat skenario model tersebut disajikan pada Tabel 4 dan Tabel 5.

TABEL 4

(Hasil skenario matrix utama setiap model)

Skenario	Accuracy	Macro F1 Score	Macro Precision	Macro Recall	Macro AUC-ROC
M1	0,9650	0,8667	0,8867	0,8504	0,9846
M2	0,9750	0,9273	0,9273	0,8996	0,9962
M3	0,9700	0,9605	0,9605	0,8349	0,9936
M4	0,9500	0,8116	0,8116	0,8584	0,9907


TABEL 5

(Hasil evaluasi *recall* dan *Precision* setiap kelas pada setiap model)

Skenario	P(N)	R(N)	P(P)	R(P)	P(Y)	R(Y)
M1	0,9000	0,8571	0,7778	0,7000	0,9825	0,9941
M2	0,9048	0,9048	0,8889	0,8000	0,9882	0,9941
M3	0,9048	0,9048	1,0000	0,6000	0,9769	1,0000
M4	0,8636	0,9048	0,5833	0,7000	0,9880	0,9704

Berdasarkan Tabel 4, skenario M2 menunjukkan performa terbaik pada sebagian besar matrik evaluasi, dengan akurasi 0,9750 dan *macro F1-score* 0,9127, sehingga menjadi model paling konsisten dalam mengklasifikasikan tiga kelas (N, P, Y). Keunggulan ini dipengaruhi oleh penerapan SMOTE yang menyeimbangkan distribusi data pelatihan tanpa mengubah arsitektur maupun *hyperparameter* model. Sebaliknya, skenario M3 yang hanya menerapkan penyesuaian parameter pelatihan tanpa SMOTE menunjukkan performa terendah, yang mengindikasikan


bahwa ketidakseimbangan kelas sangat mempengaruhi kemampuan model dalam mengenali kelas minoritas, khususnya kelas Prediabetes (P). Sementara itu, skenario M4 yang menggabungkan SMOTE dan *hyperparameter tuning* menghasilkan performa yang cukup baik, namun masih berada di bawah M2. Perbandingan performa antar skenario selanjutnya divisualisasikan pada Gambar 4 hingga Gambar 9 untuk memperjelas interpretasi hasil.



GAMBAR 4

(Visualisasi nilai *confusion matrix* pada skenario model 1)


Berdasarkan gambar 4, terlihat visualisasi *confusion matrix* dari proses perancangan model ANN pada skenario model 1, yaitu perancangan model ANN tanpa proses SMOTE dan optimasi *hyperparameter tuning*.



GAMBAR 5

(Visualisasi nilai *confusion matrix* pada skenario model 2)


Berdasarkan gambar 5, terlihat visualisasi *confusion matrix* dari proses perancangan model ANN pada skenario model 2, yaitu perancangan model ANN tanpa proses SMOTE dan optimasi *hyperparameter tuning*.



GAMBAR 6

(Visualisasi *history training* model pada baseline algoritma ANN)


Berdasarkan gambar 6, terlihat grafik pelatihan model 1, yaitu perancangan sebuah model algoritma ANN tanpa adanya proses pelatihan dengan teknik SMOTE dan optimasi *hyperparameter tuning*.



GAMBAR 7

(Visualisasi *history training* model pada baseline algoritma ANN dengan teknik SMOTE)


Berdasarkan gambar 7, terlihat grafik pelatihan model 2, yaitu perancangan sebuah model baseline algoritma ANN dengan proses pelatihan dengan teknik SMOTE dan tanpa optimasi *hyperparameter tuning*.



GAMBAR 8

(Visualisasi *history training* model pada baseline algoritma ANN dengan optimasi *hyperparameter tuning* dengan metode *random search*)

Berdasarkan gambar 8, terlihat grafik pelatihan model 3, yaitu perancangan sebuah model baseline algoritma ANN dengan proses pelatihan dengan optimasi *hyperparameter tuning* tanpa teknik SMOTE.



GAMBAR 9

(Visualisasi *history training* model pada baseline algoritma ANN dengan optimasi *hyperparameter tuning* dengan metode *random search*)

Berdasarkan gambar 9, terlihat grafik pelatihan model 4, yaitu perancangan sebuah model baseline algoritma ANN dengan proses pelatihan dengan optimasi *hyperparameter tuning* dan teknik SMOTE.

E. Pembahasan

Hasil evaluasi model *Artificial Neural Network* (ANN) pada empat skenario menunjukkan bahwa performa model sangat dipengaruhi oleh kualitas data, distribusi kelas, serta konfigurasi pelatihan. Berdasarkan hasil evaluasi dan visualisasi performa, skenario M2 (ANN dengan menggunakan SMOTE) menunjukkan kinerja paling optimal dibandingkan skenario lainnya.

Perbedaan paling menonjol terlihat pada kemampuan model dalam mengenali kelas Prediabetes (P) yang merupakan kelas minoritas pada *dataset* asli. Tanpa

penerapan SMOTE, seperti pada skenario M3, nilai recall kelas P hanya mencapai 0,6000, menunjukkan bahwa model masih kesulitan mengidentifikasi sebagian besar kasus pradiabetes. Sebaliknya, pada skenario M2, nilai *recall* meningkat menjadi 0,8000, yang menunjukkan bahwa penyeimbangan data mampu meningkatkan sensitivitas model terhadap kelas minoritas. Temuan ini sejalan dengan riset terdahulu yang menyatakan bahwa ketidakseimbangan kelas merupakan tantangan utama dalam klasifikasi data medis [9].

Keunggulan skenario M2 juga menegaskan bahwa kualitas distribusi data memiliki pengaruh yang lebih besar dibandingkan peningkatan kompleksitas arsitektur model. Skenario M3, yang hanya mengandalkan penyesuaian parameter pelatihan tanpa SMOTE, menunjukkan performa lebih rendah. Selain itu, fitur klinis seperti nilai HbA1c khususnya menjadi indikator yang paling stabil dalam mengidentifikasi risiko diabetes tipe 2. Pola ini juga terlihat pada *dataset*, di mana sebagian besar data pada kelas diabetes memiliki nilai HbA1c di atas ambang normal, sehingga membantu model ANN mengenali pola klasifikasi dengan lebih baik [26].

Arsitektur ANN yang digunakan dalam riset ini relatif sederhana, yaitu dua lapisan tersembunyi dengan fungsi aktivasi ReLU dan mekanisme *dropout*. Meskipun demikian, model mampu menghasilkan performa yang kompetitif pada data tabular klinis. Hal ini menunjukkan bahwa model *feedforward* sederhana dapat bekerja efektif pada data medis, terutama jika didukung oleh proses pra-pemrosesan yang tepat [10]. Skenario M4, yang menggabungkan SMOTE dan penyesuaian *hyperparameter*, menghasilkan performa yang cukup baik dengan akurasi 0,9500 dan *macro recall* 0,8331 [19]. Hal ini menunjukkan bahwa pengaturan parameter pelatihan dapat meningkatkan stabilitas model, meskipun peningkatannya tidak melampaui performa skenario M2 [23]. Sebaliknya, skenario M1 dan M3 menunjukkan performa yang lebih rendah, yang mengindikasikan bahwa akurasi tinggi pada data tidak seimbang dapat menimbulkan bias terhadap kelas mayoritas [24]. Temuan lain yang penting adalah nilai *Macro AUC-ROC* yang sangat tinggi pada skenario M2 yaitu 0,9962, yang menunjukkan kemampuan pemisahan antar kelas yang sangat baik. Dengan demikian, penyeimbangan data terbukti berperan penting dalam meningkatkan kemampuan klasifikasi model.

V. KESIMPULAN

Berdasarkan hasil riset, model *Artificial Neural Network* (ANN) menunjukkan kualitas performa yang baik ketika *dataset* telah melalui proses pra-pemrosesan yang tepat dan penyeimbangan distribusi kelas. Skenario M2 terbukti sebagai model terbaik dengan akurasi sebesar 0,985 dengan nilai *macro F1-score* 0,9273. Teknik SMOTE secara efektif meningkatkan sensitivitas model terhadap kelas Prediabetes, dengan *recall* meningkat dari 0,7000 (M1) menjadi 0,8000 (M2). *Hyperparameter tuning* melalui metode *random search* berkontribusi pada stabilitas model, namun tidak berdampak signifikan terhadap penyeimbangan data. Riset selanjutnya disarankan dapat mengeksplorasi *dataset* yang lebih besar, membandingkan metode ANN dengan algoritma *ensemble* lainnya, seperti *random forest*, serta menerapkan

interpretabilitas model untuk implementasi klinis berbasis kecerdasan buatan.

REFERENSI

- [1] J. Li, V. Pandian, P. M. Davidson, Y. Song, N. Chen, and D. Y. T. Fong, "Burden and attributable risk factors of non-communicable diseases and subtypes in 204 countries and territories, 1990-2021: a systematic analysis for the global burden of disease study 2021," *Int. J. Surg.*, vol. 111, no. 3, pp. 2385–2397, Mar. 2025, doi: 10.1097/JS9.0000000000002260.
- [2] N. Novia Kusumaningsih and A. Alwi, "Tantangan Penyakit Tidak Menular di Tengah Perubahan Gaya Hidup," *Indo-MathEdu Intellectuals Journal*, vol. 6, no. 2, pp. 2393–2403, Apr. 2025, doi: 10.54373/imej.v6i2.2834.
- [3] R. Pahlevi, "Jumlah Penderita Diabetes Indonesia Terbesar Kelima di Dunia," <https://databoks.katadata.co.id/>, 2025.
- [4] A. Kulkarni, A. R. Thool, and S. Daigavane, *Understanding the Clinical Relationship Between Diabetic Retinopathy, Nephropathy, and Neuropathy: A Comprehensive Review*. Cureus, 2024. doi: 10.7759/cureus.56674.
- [5] N. Katiyar, H. K. Thakur, and A. Ghatak, "Recent advancements using machine learning & deep learning approaches for diabetes detection: a systematic review," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 9, Sep. 2024, doi: 10.1016/j.prime.2024.100661.
- [6] A. Z. Mustaqim, N. A. Fadil, and D. A. Tyas, "Artificial Neural Network for Classification Task in Tabular Datasets and Image Processing: A Systematic Literature Review," *Jurnal Online Informatika*, vol. 8, no. 2, pp. 158–168, Dec. 2023, doi: 10.15575/join.v8i2.1002.
- [7] N. Faulina, "Sciencestatistics Journal of Statistics, Probability, and Its Application Implementation Of Artificial Neural Network (ANN) Classification In Type 2 Diabetes Mellitus Cases," vol. 2, no. 2, pp. 80–92, 2024.
- [8] A. Malik and C. Tepe, "Improving Early Diabetes Diagnosis : A Machine Learning Approach for Class Imbalance Mitigation," *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 11, no. 3, pp. 861–874, Jun. 2025, doi: 10.32628/cseit25113322.
- [9] S. Prasanth, K. Banujan, and K. Btgs, "Hyper Parameter Tuned Ensemble Approach for Gestational Diabetes Prediction," in *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies, 3ICT 2021, Institute of Electrical and Electronics Engineers Inc*, Sep. 2021, pp. 18–23. doi: 10.1109/3ICT53449.2021.9581926.
- [10] W. Pannakkong, K. Thiwa-Anont, K. Singthong, P. Parthanadee, and J. Buddhakulsomsiri, "Hyperparameter Tuning of Machine Learning Algorithms Using Response Surface Methodology: A Case Study of ANN, SVM, and DBN," *Math.*

- Probl. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/8513719.
- [11] G. R. ; S. M. J. I., "Type 2 Diabetes," in *StatPearls [Internet]*, StatPearls, 2023. Accessed: Apr. 02, 2025. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK513253/>
- [12] R. S. Nurhalizah, R. Ardianto, and P. Purwono, "Analisis Supervised dan Unsupervised Learning pada Machine Learning: Systematic Literature Review," *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, pp. 61–72, Aug. 2024, doi: 10.54082/jiki.168.
- [13] V. V Virginia, U. M. Mbanaso, E. S. Chaku, I. O. Clementina, and G. Aimufua, "Deep learning and convolutional neural networks (CNNs)," *GAS Journal of Engineering and Technology (GASJET)*, vol. 2, no. 11, p. 2025, 2025, doi: 10.5281/zenodo.17552650.
- [14] P. Theotokis, "Human Brain Inspired Artificial Intelligence Neural Networks," *J. Integr. Neurosci.*, vol. 24, no. 4, Apr. 2025, doi: 10.31083/JIN26684.
- [15] I. D. Mienye and T. G. Swart, "A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications," *Information (Switzerland)*, vol. 15, no. 12, Dec. 2024, doi: 10.3390/info15120755.
- [16] K. Wang, L. Wang, and J. Sun, "The data analysis of sports training by ID3 decision tree algorithm and deep learning," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-99996-5.
- [17] P. Prestasi, A. Mahasiswa, M. Nilai, M. Kuliah, and D. Tingkat, "Penerapan Artificial Neural Network (ANN)," 2023.
- [18] F. Z. El-Hassani, F. Belhabib, N. E. Joudar, and K. Haddouch, "Evolutionary algorithm-based hyperparameter tuning of one-dimensional CNNs for diabetes mellitus prediction," *Evol. Intell.*, vol. 17, no. 5–6, pp. 3655–3674, Oct. 2024, doi: 10.1007/s12065-024-00950-7.
- [19] H. Ulutas, R. B. Günay, and M. E. Sahin, "Detecting diabetes in an ensemble model using a unique PSO-GWO hybrid approach to hyperparameter optimization," *Neural Comput. Appl.*, vol. 36, no. 29, pp. 18313–18341, Oct. 2024, doi: 10.1007/s00521-024-10160-y.
- [20] M. Altalhan, A. Algarni, and M. T.-H. Alouane, "Imbalanced Data Problem in Machine Learning: A Review," *IEEE Access*, vol. 13, pp. 13686–13699, 2025, doi: 10.1109/ACCESS.2025.3531662.
- [21] D. Tourt, Q. E. Booker, and C. M. Rebman, "Strategic application of SMOTE and its variants to enhance AI-driven healthcare classification in imbalanced datasets," *Issues in Information Systems*, vol. 26, no. 2, pp. 70–85, 2025, doi: 10.48009/2_iis_106.
- [22] N. G. Ramadhan and A. Romadhony, "Preprocessing Handling to Enhance Detection of Type 2 Diabetes Mellitus based on Random Forest."
- [23] G. L. Aruna Kumari, P. Padmaja, and J. G. Suma, "A novel method for prediction of diabetes mellitus using deep convolutional neural network and long short-term memory," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 26, no. 1, pp. 404–413, Apr. 2022, doi: 10.11591/ijeecs.v26.i1.pp404-413.
- [24] N. Nipa, M. H. Riyad, S. Satu, Walliullah, K. C. Howlader, and M. A. Moni, "Clinically adaptable machine learning model to identify early appreciable features of diabetes," *Intelligent Medicine*, vol. 4, no. 1, pp. 22–32, Feb. 2024, doi: 10.1016/j.imed.2023.01.003.
- [25] R. Ahlam, "Diabetes Dataset," 2025.
- [26] R. Islam, A. Sultana, and M. R. Islam, "A comprehensive review for chronic disease prediction using machine learning algorithms," *Journal of Electrical Systems and Information Technology*, vol. 11, no. 1, Jul. 2024, doi: 10.1186/s43067-024-00150-4.