

Analisa Klasifikasi Penyakit Diabetes dengan Algoritma Neural Network

Sutrisno^{1)*}, Jupron²

¹⁾²⁾Universitas Pamulang

Jl. Surya Kencana No.1, Pamulang Barat, Tangerang Selatan, Banten, Indonesia, 15417.

¹⁾nino.soetrisno@gmail.com

²⁾dosen02664@unpam.ac.id

Article history:

Received 22 Februari 2024;
Revised 15 March 2024;
Accepted 25 April 2024;
Available online 30 April 2024

Keywords:

Diabetes
Fine tuning
Hidden layer
Minmax scaler
Neural Network

Abstract

Metode yang populer dan efektif untuk mengidentifikasi dan klasifikasi diabetes adalah algoritma deep learning untuk klasifikasi dataset diabetes. Algoritma *deep learning*, terutama jaringan saraf tiruan juga dikenal sebagai neural networks telah terbukti sangat efektif dalam menangani tugas klasifikasi data medis, seperti diabetes. Dalam penelitian sebelumnya, algoritma neural network digunakan untuk mengklasifikasikan penyakit diabetes, tetapi nilai akurasi masih di bawah 80,5%. Karena nilai akurasi masih kurang maksimal, penelitian ini bertujuan untuk meningkatkannya. Penggunaan metode pemrosesan yang lebih akurat, *fine tuning hyperparameter*, untuk memastikan data sudah normal pada setiap fitur yaitu dengan metode normalisasi standard, kemudian menambahkan hidden layer sebanyak 2 layer dengan harapan mempelajari klasifikasi yang tidak bisa dipisahkan secara linier. Dalam penelitian ini, beberapa langkah pembaharuan dilakukan selain besaran *hidden layer* juga besaran *test size*. Pembaruan ini bertujuan untuk meningkatkan akurasi yang lebih besar, serta hasil yang lebih baik untuk presisi, recall dan F1. Artikel ini menggunakan data umum atau sekunder dari laman Kaggle. Penelitian ini dilakukan untuk meningkatkan pengetahuan tentang cara mencegah diabetes. Gejala penyakit ini termasuk kadar gula sewaktu lebih dari 200 mg/dl dan kadar gula puasa lebih dari 126.mg/dl, antara tahun 1998 dan 2014, Badan Kesehatan Dunia melaporkan peningkatan dramatis dalam jumlah kasus diabetes di seluruh dunia, dari 108 juta menjadi 422 juta.

I. PENDAHULUAN

Diabetes adalah kondisi medis yang ditunjukkan oleh kadar gula darah tinggi. Diabetes adalah salah satu penyebab utama penyakit jantung koroner dan stroke iskemik. Diabetes dapat terjadi ketika pankreas tidak menghasilkan cukup insulin untuk tubuh atau ketika tubuh tidak dapat menggunakan insulin yang dihasilkannya secara efektif. Insulin adalah hormon yang mengontrol gula darah. Diabetes adalah salah satu penyakit dengan tingkat pertumbuhan tertinggi di seluruh dunia (4.444). Organisasi Kesehatan Dunia (WHO) melaporkan bahwa jumlah kasus diabetes meningkat pesat dari 108 juta pada tahun 1980 menjadi 422 juta pada tahun 2014. Ini adalah peningkatan empat kali lipat dari tiga puluh tahun sebelumnya [1] [2]. Angka ini meningkat lebih cepat di negara-negara berpendapatan rendah dan menengah.

Banyak penelitian medis telah dilakukan untuk mengklasifikasikan penyakit. Pembelajaran mesin dari data memungkinkan komputer untuk membuat prediksi atau klasifikasi berdasarkan data, yang menjadikannya dua pendekatan pembelajaran mesin yang paling populer [3] [4]. Mereka dapat mengurangi biaya dan mempercepat waktu diagnosa.

Dalam penelitian sebelumnya tentang klasifikasi diabetes [4], ADAPtive learning routine (ADAP) digunakan pada dataset Pima Indian Diabetes, dan ditemukan bahwa algoritma ini memiliki sensitivitas dan spesifisitas sebesar 76% [5]. Selain itu, ketika algoritma pengajaran supervisi digunakan pada dataset yang sama, nilai akurasi Logistic Regression adalah 76.80%. Hasil ini sangat mirip dengan temuan penelitian sebelumnya [6], yang menemukan bahwa algoritma SVM memiliki akurasi tertinggi 77,92%, seperti yang ditunjukkan dalam penelitian sebelumnya [7], yang menemukan bahwa algoritma Naive Bayes memiliki akurasi 76,30%. Namun, penelitian yang dilakukan pada data yang sama menggunakan RBF SVM dan polynomial

* Corresponding author

SVM menunjukkan akurasi yang lebih tinggi, dengan akurasi tertinggi 84,71% untuk kasus normal dan 82,41% untuk kasus besar. Metode yang diuji oleh Savas dan tim [8] yang menggunakan algoritma Backward Elimination dan SVM menunjukkan hasil yang lebih baik, dengan presentase data pelatihan sebesar 90% dan pemilihan fitur sebesar 85,71 persen [9]. Mencoba menggunakan dataset hospital Frankfurt, yang memiliki fitur yang sama dengan dataset Diabetes Pima Indians, memberikan nilai akurasi tertinggi sebesar 98,20% dengan algoritma Decision Tree.

Sistem pembelajaran neural memanfaatkan informasi seperti jaringan syaraf manusia. Untuk menjalankan Neural Network, program komputer dapat digunakan, seperti library keras Python dan tools tensorflow, yang dapat menyelesaikan banyak proses perhitungan. Pengenalan pola adalah salah satu pengguna Neural Network. Sistem pengenalan pola adalah bagian penting dari proses meniru cara manusia bekerja [10].

II. TINJAUAN PUSTAKA

Penelitian menunjukkan bahwa pasien dengan gejala diabetes disarankan untuk lebih mengontrol diri karena diabetes adalah masalah kesehatan masyarakat global yang signifikan dengan perkiraan prevalensi 9,3% pada tahun 2019. Oleh karena itu, penelitian menunjukkan bahwa pasien diabetes harus meningkatkan pengawasan diri mereka untuk mencegah komplikasi serius dan mengurangi risiko komplikasi tambahan [11],[12]. Pada tahun yang sama, Indonesia adalah merupakan negara dengan jumlah penderita diabetes yang jumlahnya tertinggi dengan 10,7 juta orang, kemudian level dibawahnya adalah China, India, Amerika Serikat, Pakistan, Brazil, dan Meksiko. Pada tahun 2020, prevalensi diabetes meningkat menjadi 10,8 juta orang dengan 6,2%, dan diperkirakan akan mencapai 16,7 juta penderita pada tahun 2045 [1]. Selama abad kedua puluh satu, diabetes menjadi salah satu masalah kesehatan masyarakat yang paling penting. Ini menjadi pandemi terbesar di seluruh dunia, baik di negara maju maupun berkembang, dan merupakan salah satu penyebab kematian paling umum selain bagi penderita penyakit jantung dan pembuluh darah [11].

Menurut Punnthakee et al. [13], diabetes termasuk dalam kategori berikut: Pertama adalah diabetes melitus (Dm-01) tipe satu adalah diabetes yang terpapar oleh kerusakan sel pankreas akibat proses autoimun atau idiopatik, yang mengakibatkan penurunan atau penghentian produksi insulin. kedua adalah kadar glukosa darah yang tinggi dikombinasikan dengan resistensi insulin dan defisiensi insulin relatif adalah tanda diabetes melitus (Dm-02) tipe 2, diabetes jenis ini biasanya muncul pada orang yang berusia lebih dari dua puluh tahun. Ketiga adalah diabetes melitus gestasional adalah intoleransi glukosa selama masa pengenalan pertama kehamilan, kemudian keempat adalah jenis khusus lainnya mencakup berbagai jenis penyakit yang tidak biasa, terutama diabetes yang ditentukan secara genetik atau diabetes yang dikaitkan dengan penyakit lain atau penggunaan narkoba.

Menurut Azhari et al. [14], ada sejumlah metode klasifikasi, seperti: Pohon Keputusan, *rule-based classifiers*, *Bayesian support vector machine classifiers* (BSVM), *Artificial Neural Networks* (ANN), *Lazy Learners*, dan *ensemble methods*. Menurut penelitian lain yang mensupportnya, keandalan *logistic regression* memiliki akurasi 85% dalam memprediksi penyakit kardiovaskular [15]. Pada artikel yang lain memprediksi penyakit ginjal kronis, dan hasilnya menunjukkan bahwa *logistic regression* cenderung memiliki overfitting yang lebih rendah daripada hutan random dan neural network [16]. Selain itu, telah ditunjukkan bahwa algoritma *logistic regression* lebih akurat daripada k-NN, *support vector machine* (SVM), pohon keputusan, dan hutan random ketika digunakan untuk mengidentifikasi dan memprediksi penyakit hati dengan melakukan perbandingan desimal[4]. Selain itu, penelitian lain membandingkan tiga model pembelajaran mesin *neural network* untuk mendeteksi diabetes pada 768 data Kaggle. Hasilnya menunjukkan bahwa algoritma *logistic regression* memiliki akurasi 75,78%, dibandingkan dengan 74,87% dan 69,27% dari kedua model lainnya [21]. Selain itu, evaluasi kinerja algoritma *logistic regression* dibandingkan dengan algoritma pembelajaran mesin lainnya menunjukkan bahwa algoritma *logistic regression* [17]

Pengolahan data dibagi menjadi berbagai kelompok berdasarkan tugas yang dapat dilakukannya [19]. Kelompok pertama adalah deskripsi, yang menunjukkan pola dan kecenderungan dalam data; kelompok kedua adalah estimasi, yang hampir sama dengan klasifikasi, tetapi atribut target estimasi lebih besar daripada kategori. Klasifikasi adalah pembagian data menjadi beberapa bagian atau kelas. Prediksi dan klasifikasi hampir sama. Salah satu contohnya adalah klasifikasi berat badan menjadi gemuk, sedang, atau kurus serta klasifikasi diabetes menjadi positif atau negatif. Hasil observasi yang serupa dikelompokkan dalam kelompok yang sama dikenal sebagai pengklusteran. Salah satu tugas asosiasi data mining adalah untuk menyediakan informasi tentang hubungan item dalam database dan menemukan atribut yang muncul secara bersamaan.

Klasifikasi adalah proses mengkategorikan sekumpulan data kemudian membaginya ke dalam kelas tertentu dari jumlah kelas yang tersedia. Menurut [22], klasifikasi adalah proses menemukan kumpulan model (fungsi) yang dapat menjelaskan dan membedakan kelas-kelas data. Ini dapat digambarkan sebagai tugas mengajarkan atau mengajarkan fungsi target dengan memetakan setiap set atribut ke dalam jumlah label kelas yang tersedia [21]. Tujuannya adalah untuk memprediksi kelas objek yang kelasnya belum diketahui dengan menggunakan himpunan model tersebut..

III. METHODS

Penelitian ini menggunakan data dari <https://www.kaggle.com>, yang berukuran 768 titik. Ada 9 variabel independen dan dependen, masing-masing berisi deskripsi penyakit diabetes. Variabel-variabel ini adalah sebagai berikut: *Pregnancies*: to express the Number of pregnancies, merupakan data jumlah kehamilan pasien, nama atribut *Pregnancies* ini dengan type data integer, Glukosa: Untuk menyatakan kadar Glukosa dalam darah dengan type data integer, *BloodPressure*: to express the Blood pressure measurement, untuk menyatakan pengukuran tekanan darah dengan type data integer, Ketebalan kulit, Untuk menyatakan ketebalan kulit. *Insulin*: untuk menyatakan kadar Insulin dalam darah dengan type data integer. *BMI*: to express the Body mass index, untuk menyatakan indeks massa tubuh, dengan type data float. *DiabetesPedigreeFunction*: To express the Diabetes percentage, untuk menyatakan persentase Diabetes, dengan type data float. *Umur*: to express the age, untuk menyatakan usia, dengan type data integer. *Hasil*: untuk menyatakan hasil akhir 1 adalah Ya dan 0 adalah Tidak, dengan type data integer, 268 dari 768 adalah 1 dan 500 dari 768 adalah 0.

Proses mengambil dataset ini dengan cara *download* pada site kaggle dan kemudian diextract pada folder content google colab. Setelah dataset tersimpan dengan baik, kemudian dilanjutkan dengan import beberapa *library* Python, *library* yang pertama yaitu NumPy (*Numerical Python*), *library* Python yang fokus pada *scientific computing*. Numpy menyediakan fungsi yang siap digunakan untuk memudahkan melakukan perhitungan saintifik seperti *matriks*, aljabar, statistik dan sebagainya. *Library* selanjutnya adalah *pandas*, kata *pandas* juga merujuk pada *library* python sumber terbuka yang populer untuk manipulasi dan analisis data. *Libray* *pandas* menyediakan struktur data seperti *Data Frame* dan *Series*, yang merupakan *tools* canggih untuk bekerja dengan data terstruktur. Ini banyak digunakan dalam data science, *machine learning*, dan bidang lain untuk tugas-tugas seperti membersihkan data, menganalisis data dan memvisualisasikan data. Nama *pandas* berasal dari istilah "data panel", yang merupakan istilah ekonometrik untuk dataset terstruktur multidimensi. *Seaborn* adalah *library* visualisasi data statistik berdasarkan *Matplotlib*. Ini menyediakan antarmuka tingkat tinggi untuk menggambar grafik statistik yang menarik dan informatif. *Seaborn* hadir dengan beberapa tema dan palet warna bawaan untuk memudahkan pembuatan visualisasi yang estetis. Hal ini sangat berguna untuk membuat visualisasi kompleks dengan sintaksis yang ringkas. Terlampir pada gambar.1 adalah display lima *records* pertama, empat *records* terakhir dan empat *records* acak dari dataset yang terdiri dari 768 baris dan 9 kolom, pada gambar ini mengecek bahwa dataset yang digunakan penelitian sesuai dengan informai awal.

Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome	
0	6	148	72	35	0	33.6	0.627	50	1
1	1	85	66	29	0	26.6	0.351	31	0
2	8	183	64	0	0	23.3	0.672	32	1
3	1	89	66	23	94	28.1	0.167	21	0
4	0	137	40	35	168	43.1	2.288	33	1
Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome	
764	2	122	70	27	0	36.8	0.340	27	0
765	5	121	72	23	112	26.2	0.245	30	0
766	1	126	60	0	0	30.1	0.349	47	1
767	1	93	70	31	0	30.4	0.315	23	0
Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome	
14	5	166	72	19	175	25.8	0.587	51	1
171	6	134	70	23	130	35.4	0.542	29	1
678	3	121	52	0	0	36.0	0.127	25	1
54	7	150	66	42	342	34.7	0.718	42	0

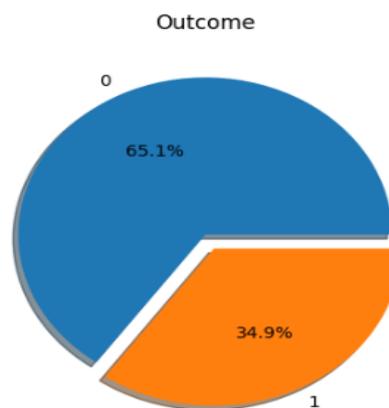
Gambar.1 Dataset

Pembersihan dataset merupakan langkah yang dilakukan untuk memastikan data bersih dari *noise*, memastikan apakah ada atau tidak data duplikat pada setiap baris, jika ditemukan maka dihapus dari *dataframe*, pembersihan data juga dilakukan dengan mengecek data bersih dari data null pada setiap baris, data null merupakan data yang nilainya hilang, tidak berisi, tidak diketahui.

Pada gambar.2 merupakan data visualisasi yang menggambarkan data pada dataset, dimana bahwa ada 65.1 % dari 768 yaitu 500 merupakan penderita diabetes dan 34,9% dari 768 yaitu 268 merupakan non penderita diabetes. Selanjutnya proses memisahkan *dataframe* yang masuk ke x dan y, dimana data (x) menjadi 8 kolom yang terdiri dari *Pregnancies*, *Glucose*, *BloodPressure*, *SkinThickness*, *Insulin*, *BMI*, *Diabetes Pedigree*

Function, *Age*, untuk data (*y*) beranggotakan 1 kolom yaitu *Outcome*. Dalam pembelajaran mesin, penskalaan fitur digunakan untuk menstandarisasi rentang variabel independen atau fitur kumpulan data. Hal ini sering kali penting untuk algoritma yang sensitif terhadap skala fitur masukan, seperti algoritme berbasis penurunan gradien, k-nearest neighbours, dan mesin vektor pendukung. Metode umum untuk penskalaan fitur mencakup Penskalaan Min-Max dan Standardisasi.

Membagi data menjadi dua atau tiga set: set pelatihan, set validasi dan set pengujian. Set pelatihan digunakan untuk melatih model, set validasi digunakan untuk penyetelan *hyper parameter* dan set pengujian digunakan untuk menguji kinerja akhir model. Besaran data training atau pelatihan sebesar 20 % sehingga mendapatkan nilai $x_{train} = (614,8)$ $y_{train} = (614)$ besaran nilai pengujian sebesar $y_{test} = (154,8)$ $y_{test} = (154)$ dimana 614 ditambah 154 total 768. Setelah kegiatan pembagian data untuk pelatihan dan pengujian, proses selanjutnya adalah membuat klasifikasi dengan nilai x_{train} y_{train} dan membuat prediksi dengan algoritma Neural Network dengan nilai x_{test} (154,8) neural network prediksinya sebesar (154) seperti yang tercatat dalam tabel.1.



Gambar.2 Data Visualisasi

TABEL 1
 MATRIK PREDIKSI

Besaran	x	y
80% Training	(614, 8)	614
80% Testing	(154, 8)	154
Total		

Pada tabel 2 model evaluasi untuk mendapatkan evaluasi nilai yang didapat dari tabel matrik prediksi diatas, nilai akurasi pelatihan (training) dari neural network = model score neural network (nilai x_{train} , y_{train})*100%, Akurasi testing score dari neural network = model score neural network (nilai x_{test} , y_{test})*100%, Akurasi score dengan (nilai y_{test} , neural network_pred)*100%.

TABEL 2
 MODEL EVALUASI TRAIN & TEST SCORE

Keterangan	Nilai
Train Accuracy of Neural Network	81,11
Accuracy (test) score of Neural Network	78,57
Accuracy score of Neural Network	80,52

IV. RESULTS

Pada gambar.3 Matriks *Confusion* adalah alat yang populer dalam pembelajaran mesin dan statistik untuk mengevaluasi kinerja algoritma klasifikasi, *tools* ini memberikan representasi tabel dari kelas aktual vs. prediksi untuk dataset. Pada dasarnya, matriks confusion memberikan informasi tentang bagaimana hasil klasifikasi sistem (model) dibandingkan dengan hasil klasifikasi sebenarnya. Tabel matriks confusion matrix menunjukkan bagaimana model klasifikasi berfungsi pada dataset yang nilai sebenarnya diketahui.

Dibawah ini nilai prediksi dan nilai aktual yang bersarannya berbeda.

True Negative (TN) : 86

False Positive (FP) : 11

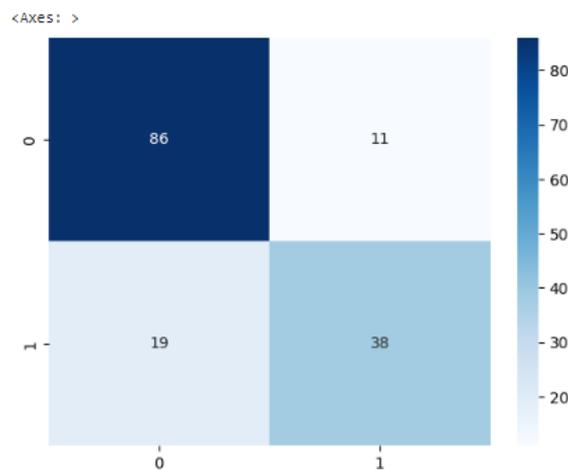
False Negative (FN) : 19

True Positive (TP) : 38
Rates of Accuracy: 80.51948051948052
Rates of Misclassification: 19.480519480519483

True Positive (TP) : Merupakan data positif yang diprediksi benar, pasien yang menderita diabetes (class 1) dan dari model yang dibuat memprediksi pasien tersebut menderita diabetes (class 1). *False Positive (FP)*-Kesalahan tipe I: Merupakan data negatif tapi diprediksi sebagai data positif. *sample*nya : pasien tidak menderita diabetes (class 2) tetapi dari model yang telah memprediksi pasien tersebut menderita diabetes (class 1). *False Negative (FN)*-Kesalahan tipe II: Merupakan data positif namun diprediksi sebagai data negatif. *sample*nya, pasien menderita diabetes (class 1) tetapi dari model yang dibuat memprediksi pasien tersebut tidak menderita diabetes (class 2). *True Negative (TN)*: Merupakan data negatif yang diprediksi benar, pasien tidak yang menderita diabetes (class 2) dan dari model yang dibuat memprediksi pasien tersebut tidak menderita diabetes (class 2).

Contoh prediksi diabetes diatas dapat dikaitkan dengan pernyataan bahwa beberapa kasus "Kesalahan Tipe II" lebih berbahaya. Jika pasien tidak menderita diabetes tetapi diprediksi menderita diabetes (FP), mereka dapat mengetahui keadaan sebenarnya bahwa mereka benar-benar tidak menderita diabetes pada diagnosa selanjutnya. Sebaliknya, jika pasien sebenarnya menderita diabetes tetapi diprediksi tidak menderita diabetes (FN), mereka akan mengetahui keadaan sebenarnya terlambat dan tidak akan segera mengambil tindakan pencegahan medis untuk mencegah diabetes. Oleh karena itu, "Kesalahan Tipe II" lebih berbahaya.

Ada cara yang lebih mudah untuk mengingatnya, yaitu: Jika diawali dengan True maka prediksinya adalah benar, entah diprediksi terjadi atau tidak terjadi. Jika diawali dengan False maka prediksinya adalah salah. Positif dan negatif merupakan hasil prediksi dari model. Pada artikel ini model yang buat ingin memberikan 0 false positive dan 0 false negative, tetapi itu tidak akan pernah terjadi pada praktiknya karena model mana pun tidak akan memberikan keakuratan sepenuhnya. Jika sepenuhnya akurat maka model yang buat atau data yang gunakan memiliki masalah.



Gambar 3 Matriks Confusion

Pada tabel.3 Report klasifikasi *Precision* adalah rasio observasi positif (TP) yang diprediksi dengan benar terhadap total observasi TP+FP positif yang diprediksi.

$$\text{Precision} = \text{tp} / (\text{tp} + \text{fp}) \tag{1}$$

True Negative (TN) : 86
False Positive (FP) : 11
False Negative (FN) : 19
True Positive (TP) : 38

Precision Score is: **77.55** dari $(38/(38+11))*100\%$
Mirco Avg precision Score is: 80.51948052
Marco Avg precision Score is: 79.72789116
Weighted Avg prec Score is: 80.29331213
Precision Score on non weighted score is: [81.9047619 77.55102041].

TABEL 3
REPORT KLASIFIKASI *PRECISION*

	Precision	Recall	F1	Support
0	0.819	0.887	0.852	97
1	0.775	0.667	0.717	57
accuracy			0.805	154
macro avg	0.797	0.777	0.784	154
weighted avg	0.803	0.805	0.802	154

Pada tabel.4 Report klasifikasi *Recall* adalah rasio observasi positif (TP) yang diprediksi dengan benar terhadap total observasi TP+FN positif yang diprediksi

$$recall_score = tp / (tp + fn) \quad (2)$$

True Negative (TN) : 86

False Positive (FP) : 11

False Negative (FN) : 19

True Positive (TP) : 38

Micro Avg Recall Score is : 80.51948052

Macro Avg Recall Score is : 77.66323024

Weighted_Avg_Recall_Score_is : 80.51948052

Recall_Score_on_Non_weighted_score_is: [88.65979381 66.66666667] dari **(38/(38+19))*100%**

TABEL 4
REPORT KLASIFIKASI *RECALL*

	Precision	Recall	F1	Support
0	0.819	0.887	0.852	97
1	0.775	0.667	0.717	57
accuracy			0.805	154
macro avg	0.797	0.777	0.784	154
weighted avg	0.803	0.805	0.802	154

Pada tabel.5 Report Klasifikasi F1 Score merupakan perbandingan rata-rata presisi dan recall yang dibobotkan.

$$F1\ Score = 2 * (Recall*Precision) / (Recall + Precision) \quad (3)$$

Micro Avg f1 Score is : 80.51948052

Macro Avg f1 Score is : 78.42331403

Weighted_Avg_f1_Score is : 80.17011944

F1 Score on Non weighted score is: [85.14851485 71.69811321]. dari $2 * (66.67*77.55) / (66.67+77.55)$

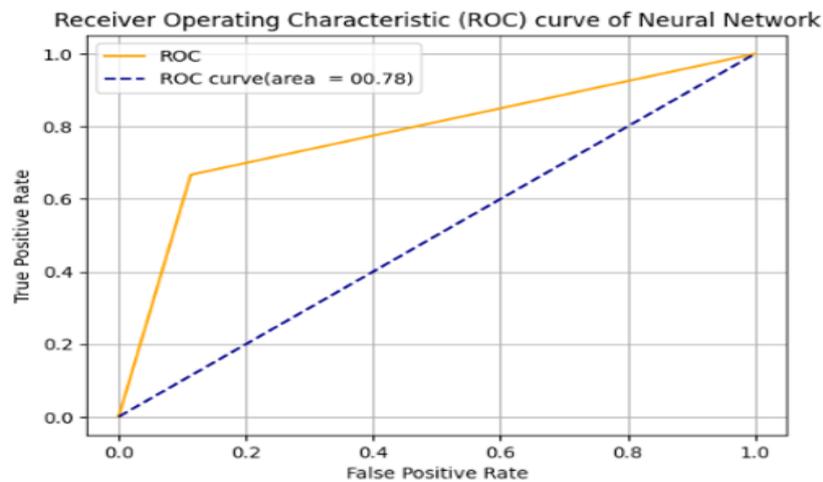
TABEL 5
REPORT KLASIFIKASI *F1*

	Precision	Recall	F1	Support
0	0.819	0.887	0.852	97
1	0.775	0.667	0.717	57
accuracy			0.805	154
macro avg	0.797	0.777	0.784	154
weighted avg	0.803	0.805	0.802	154

V. PEMBAHASAN

ROC Kurva Roc pada gambar.4 adalah salah satu metrik evaluasi yang paling penting yang harus digunakan untuk mengevaluasi seberapa baik model klasifikasi berfungsi. Kurva Roc disebut juga kurva karakteristik operasi relatif, karena merupakan perbandingan dua karakteristik utama (TPR dan FPR). Itu diplot antara sensitivitas (alias *recall* alias *True Positive rate*) dan *False Positive Rate* (FPR = 1-spesifisitas). Kurva ROC (*Reciver Operating Characteristic*) memberi tahu kita seberapa baik model dapat membedakan dua hal (misalnya apakah pasien menderita suatu penyakit atau tidak). *Area Under Curve* (AUC) membantu kami dalam memilih model yang paling cocok dari model yang kurva ROC-nya telah kita gambarkan. Pada penelitian ini menggunakan salah satu jenis model dari neural network untuk mempermudah dalam klasifikasi yang rumit

yaitu Multilayer Perceptron (MLP). Keunggulan Multi-Layer Perceptron dibandingkan dengan Single-Layer Perceptron adalah kemampuan untuk mendeteksi atau menganalisis masalah yang sangat kompleks



Gambar 4 ROC

VI. KESIMPULAN

Algoritma *Neural Network* digunakan dalam penelitian ini untuk menentukan apakah pasien terkena penyakit diabetes atau tidak. Dari 768 data, 614 dibagi menjadi data pelatihan dan 154 dibagi menjadi data pengujian. Hasil pengujian menunjukkan akurasi yang cukup baik, yaitu 81,11%, *Precision* 77,55% dan *Recall* 66,67%. Algoritma *Neural Network* memiliki nilai AUC sebesar 0,78, yang berarti klasifikasi yang baik, yang menunjukkan bahwa menggunakannya untuk klasifikasi penderita diabetes memiliki akurasi yang baik. Penelitian ini sesuai capaian target nilai akurasi yaitu > 80%, saran untuk penelitian selanjutnya dengan mencoba menaikkan prosentase nilai testing menjadi 0.25 (25%), dengan harapan menaikkan akurasi > 81.11 %, dan kemudian menambahkan hidden layer lebih banyak dari sebelumnya yaitu sebanyak 3 hidden layer.

REFERENCES

- [1] J Elflein dan (2019). "Number of people with diabetes, by country 2019", <https://www.statista.com/statistics/281082/countries-with->, 2021.
- [2] H. Nurhayati-Wolff dan (2020), "Projected number of people with diabetes," [Online], <https://www.statista.com/statistics/1052625/indonesia-diabetes-projection/>, 2021.
- [3] L.V.R. Kumari dan dkk, "Machine Learning based Diabetes Detection," *Proc. 6th Int. Conf. Commun. Electron. Syst (ICCES 2021)*, pp. 1-5, 2021.
- [4] N. Abdulhadi dan A. Al-Mousa, "Diabetes Detection Using Machine Learning Classification Methods," *Proc. 2021 Int. Conf. Inf. Technol. ICIT 2021*, p. 350–354, 2021.
- [5] Bhoi, S. K, "Prediction of Diabetes in Females of Pima Indian Heritage: A Complete," *Turkish Journal of Computer and Mathematics Education*, vol. 12, pp. 3074-3084, 2021
- [6] Agatsa, D. A, Rismala, R dan Wisesty, U. N, "Klasifikasi Pasien Pengidap Diabetes Menggunakan Metode Support Vector Machine," *eProceedings of Engineering*, vol. 7, 2018
- [7] Sisodia, D. dan Sisodia, D. S, "Prediction of diabetes using classification algorithms," *Procedia computer science*, vol. 132, pp. 1578-1585, 2018.
- [8] Maulidina, F, Rustam, Z, Hartini, S, Wibowo, V. V. P, Wirasati, I dan Sadewo, W, "Feature optimization using Backward Elimination and Support Vector Machines," *In Journal of Physics: Conference Series*, vol. 1821, p. 012006, 2021.
- [9] Daanouni, O, Cherradi, B dan Tmiri, A, "Predicting diabetes diseases using mixed data and supervised machine learning algorithms," *In Proceedings of the 4th International Conference on Smart City Applications*, pp. 1-6, 2019.
- [10] S. Mishra, R. Sachan dan D. Rajpal, "Deep Convolutional Neural Network based Detection System for Real-time Corn Plant Disease Recognition," *Procedia Comput. Sci*, vol. 167, pp. 2003-2010, 2020.
- [11] A. D. Association, "Diabetes Overview The path to understanding diabetes starts here," [Online], <https://www.diabetes.org/diabetes>, 2021.

- [12] S. Yezli, Y. Yassin, A. Mushi, B. Balkhi dan A. Khan, "Insulin Knowledge , Handling , and Storage among Diabetic Pilgrims during the Hajj Mass Gathering," *Journal of Diabetes Research*, 2021
- [13] Punthakee, Z., Goldenberg, R dan Katz, P, "Definition, Classification and Diagnosis of Diabetes, Prediabetes and Metabolic Syndrome," *Canadian Journal of Diabetes*, vol. 42, p. S10–S15, 2018.
- [14] Azhari, M, Situmorang, Z dan Rosnelly, R., "Perbandingan Akurasi, Recall dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *Media Informatika Budidarma*, vol. 5, p. 640–651, 2021.
- [15] T Ciu dan R. S. Oetama, "Logistic Regression Prediction Model for Cardiovascular Disease," *IJNMT (Int. J. New Media Technol.)*, vol. 7, p. 33–38, 2020.
- [16] R. Thammasudjarit dan dkk, "Comparison of Machine Learning with Logistic Regression for Prediction of Chronic Kidney Disease in the Thai Adult Population," *Ramathibodi Med. J*, vol. 44, pp. 1-12, 2021
- [17] S. Nusinovic dan dkk, "Logistic Regression was As Good As Machine Learning for Predicting Major Chronic Diseases," *J. Clin. Epidemiol*, vol. 122, p. 56–69, 2020
- [18] Chan, A. S, "Prediksi Kedatangan Wisatawan Pada Pariwisata Kota Batam Dengan Menggunakan Teknik Knowledge Data Discovery," *Jurnal Ilmiah Informatika*, pp. 6-11, 2018
- [19] Mardi, Y, "Klasifikasi Menggunakan Algoritma C4.5," *Edik Informatika*, vol. 2, 2018
- [20] Fitriyani., & dan Siallagan, R. A, "Prediksi Penyakit Diabetes Mellitus," *Jurnal Responsif*, vol. 3, pp. 45-46, 2021
- [21] Utomo, D. P., & Mesran, M, "Analisis Komparasi Metode Klasifikasi Data Mining dan Reduksi Atribut Pada Data Set Penyakit Jantung," *Jurnal Media Informatika Budidarma*, vol. 4, p. 440, 2020
- [22] Nasution, M. Z. F., Sitompul, O. S., & Ramli, M, "PCA based feature reduction to improve the accuracy of decision tree c4.5 classification," *Journal of Physics Conference Series*, vol. 978, 2018
- [23] D Y Utami, E Nurlelah dan F N Hasan, "Comparison of Neural Network Algorithms, Naive Bayes and Logistic Regression to Find the Highest Accuracy in Diabetes," *J. Inform. Telecommun*, vol. 1, pp. 152-159, 2021
- [24] D S Nusinovice, "Logistic Regression was good as machine learning for predicting Major Chronic Diseases," *J.Clin Epidemiol*, vol. 122, pp. 56-69, 2020
- [25] Alsalman Y S, Khamees Abu Halemah N, Alnagi E S dan Salameh W, "Using Decision Tree and Artificial Neural Network to Predict Students Academic Performance," *Conference on Informaion and Communicaon Systems ICICS 2019*, pp. 104-109, 2019.
- [26] N Varshey dan A. Sharma, "Identification and Prediction of Liver Disease Using Logistic Regression," *Eur. J. Mol. Clin. Med*, vol. 7, pp. 106-110, 2020.