

# Implementasi Case Based Reasoning Untuk Mendiagnosis Diabetes Menggunakan K-Nearest Neighbor

Muhammad Syaugi Shahab<sup>1</sup>, Mitzaqon Gholizhan Ar Romandhon<sup>2</sup>, Endin Rahmanda<sup>3</sup>, Muhammad Irfan Ardhiansyah<sup>4</sup>, Made Hanindia Prami Swari<sup>5\*</sup>

<sup>1,2,3,4,5</sup> Jurusan Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

<sup>1</sup>[20081010107@student.upnjatim.ac.id](mailto:20081010107@student.upnjatim.ac.id)

<sup>2</sup>[200810101116@student.upnjatim.ac.id](mailto:200810101116@student.upnjatim.ac.id)

<sup>3</sup>[20081010070@student.upnjatim.ac.id](mailto:20081010070@student.upnjatim.ac.id)

<sup>4</sup>[20081010051@student.upnjatim.ac.id](mailto:20081010051@student.upnjatim.ac.id)

<sup>5</sup>[madehanindia.fik@upnjatim.ac.id](mailto:madehanindia.fik@upnjatim.ac.id)

\*Corresponding author email: [madehanindia.fik@upnjatim.ac.id](mailto:madehanindia.fik@upnjatim.ac.id)

**Abstrak**— Diabetes merupakan penyakit kronis yang berpotensi menyebabkan komplikasi serius jika tidak ditangani dengan baik. Teknologi seperti Case Based Reasoning (CBR) telah digunakan untuk membantu dalam diagnosis penyakit ini. Penelitian ini menggunakan dataset dengan 768 sampel, di mana 500 non-diabetes dan 268 diabetes. K-Nearest Neighbor (K-NN) sebagai algoritma *supervised* digunakan untuk mengklasifikasi kelas berdasarkan jarak terdekat dalam data pelatihan dan pengujian dengan nilai *similarity* yang didapat dari perhitungan untuk setiap data pengujian yang dimasukkan. Dengan menerapkan algoritma K-Nearest Neighbor pada tiga skenario pengujian yang berbeda, evaluasi model menunjukkan konsistensi relatif dalam kinerja model, meskipun ada variasi dalam proporsi data pelatihan dan pengujian. Serta, terdapat sedikit penurunan dalam akurasi pada skenario dengan proporsi 80% data pelatihan dan 20% pengujian, keseragaman dalam presisi, recall, dan *f1-score* menunjukkan keandalan model dalam mengklasifikasikan kasus diabetes. Oleh karena itu, memperhatikan variasi dalam jumlah data pelatihan dan pengujian, dapat disimpulkan bahwa model CBR memiliki kinerja yang baik dalam mengidentifikasi kasus diabetes terutama dalam hasil pengujian pertama dengan nilai *similarity* yang sama.

**Kata Kunci**— Case Based Reasoning, Algoritma K-Nearest Neighbor (K-NN), Penyakit Diabetes

## I. PENDAHULUAN

Diabetes merupakan penyakit kronis yang ditandai dengan kadar gula yang melebihi batas normal. Jika tidak ditangani dengan baik, diabetes beresiko menyebabkan komplikasi pada organ tubuh seperti mata, ginjal, jantung, pembuluh darah, dan saraf. Komplikasi yang terjadi dapat menyebabkan penurunan harapan hidup serta kecacatan. [1] Diabetes dapat dideteksi melalui beberapa indikator kesehatan. *Case Based Reasoning* merupakan sebuah sistem yang dapat memproses permasalahan yang diajukan dengan menggunakan solusi pada kasus sebelumnya yang memiliki persamaan kasus. [2]. Dengan *Case Based Reasoning*, teknologi dapat membantu tenaga medis untuk memberikan diagnosis yang lebih cepat dan akurat, serta memberikan rekomendasi pengobatan yang sesuai berdasarkan kasus-kasus sebelumnya. Penggunaan CBR juga memungkinkan untuk pembaruan pengetahuan secara berkelanjutan, sehingga model diagnosis dapat terus diperbaiki

dan disesuaikan dengan perkembangan terbaru dalam bidang medis.

## II. MATERI DAN METODE

### A. Data Penelitian

Data rekam medis yang digunakan dalam penelitian ini menggunakan data dari UCI *Machine Learning Repository*. *Dataset* ini berasal dari *National Institute of Diabetes, Digestive, and Kidney Disease* [7]. *Dataset* ini berisi 768 sampel, dimana 500 sampel adalah non-diabetik sementara 268 lainnya adalah diabetik. Semua subjek dalam data ini adalah perempuan keturunan suku Indian Pima yang berusia minimal 21 tahun. Data tersebut memiliki beberapa fitur yang perlu dilatih yang dimana memiliki bobot untuk setiap gejala untuk menentukan hasil prediksi apakah memiliki penyakit diabetes atau tidak dengan hasil antara 0 dan 1, yang dimana jika hasilnya adalah 0 maka tidak diabetik dan 1 bernilai sebaliknya. Setiap fitur pada *dataset* memiliki tipe data dan rentang nilai yang berbeda seperti pada Tabel 1.

TABEL 1  
DESKRIPSI *DATASET*

Fitur	Deskripsi	Tipe Data	Rentang Nilai
Pregnancies	Jumlah kehamilan yang telah terjadi	Integer	[0, 17]
Glucose	Konsentrasi glukosa dalam plasma setelah 2 jam pada tes toleransi glukosa oral (TTGO)	Integer	[0, 199]
Blood Pressure	Tekanan darah diastolik (mm Hg)	Integer	[0, 122]
Skin Thickness	Ketebalan lipatan kulit trisep (mm)	Integer	[0, 99]
Insulin	Insulin serum pada 2 jam ( $\mu\text{h/ml}$ ).	Integer	[0, 846]
BMI	Indeks massa tubuh [berat dalam kg/(Tinggi dalam m)].	Float	[0, 67.1]

Diabetes Pedigree Function	Indikator riwayat diabetes	Float	[0.078, 2.42]
Age	Usia	Integer	[21, 81]
Outcome	Nilai biner yang menunjukkan tipe diabetik	Boolean	[0, 1]

**B. Case Based Reasoning**

Case Based Reasoning merupakan suatu metode dalam sistem pakar yang berbasiskan pengetahuan [8]. Case Base Reasoning salah satu penyelesaian masalah, dimana masalah tersebut diselesaikan dengan melihat pola atau keadaan yang telah terjadi sebelumnya [9]. Pengalaman tersebut kemudian digunakan untuk memecahkan kasus sejenis yang baru [3]. Terdapat 4 tahapan proses dalam case based reasoning, yaitu.

- 1) Retrieve merupakan proses pencarian kemiripan kasus baru dengan kumpulan kasus-kasus yang ada. Proses pencarian ini dimulai dengan tahapan mengenali masalah dan berakhir ketika kasus yang ingin dicari solusinya telah ditemukan serupa dengan kasus yang telah ada [4].
- 2) Reuse adalah proses di mana solusi dari kasus yang mirip diadaptasi dan diterapkan pada kasus baru setelah ditemukan dalam tahap retrieve [10].
- 3) Revise adalah proses evaluasi solusi yang telah diterapkan pada kasus baru dan disesuaikan berdasarkan umpan balik atau hasil yang diperoleh. Jika solusi awal tidak sepenuhnya efektif, maka akan dilakukan perbaikan dan penyesuaian hingga solusi yang optimal ditemukan [11].
- 4) Retain, dimana solusi yang berhasil diterapkan pada kasus baru dicatat untuk kemudian dapat digunakan sebagai referensi untuk kasus serupa di masa depan [12].

**C. Algoritma K-Nearest Neighbor**

K-Nearest Neighbor adalah algoritma supervised yang menggunakan informasi data training untuk mengklasifikasi objek berdasarkan jarak terdekat. K-NN bekerja dengan mencari objek yang paling dekat dalam data pelatihan untuk mengevaluasi informasi baru [5]. Algoritma ini dapat digunakan untuk melakukan klasifikasi maupun regresi [6]. Algoritma K-NN dapat digunakan untuk mencari kemiripan terhadap kasus lama dan kasus baru (similarity) [13]. Kasus yang memiliki nilai terbesar merupakan kasus yang memiliki solusi yang sama dengan kasus lama [14]. Persamaan (1) digunakan untuk menghitung nilai kesamaan (similarity) [15].

$$Similarity(problem, case) = \frac{S1 * W1 + S2 * W2 + ... + Sn * Wn}{W1 + W2 + ... + Wn} \quad (1)$$

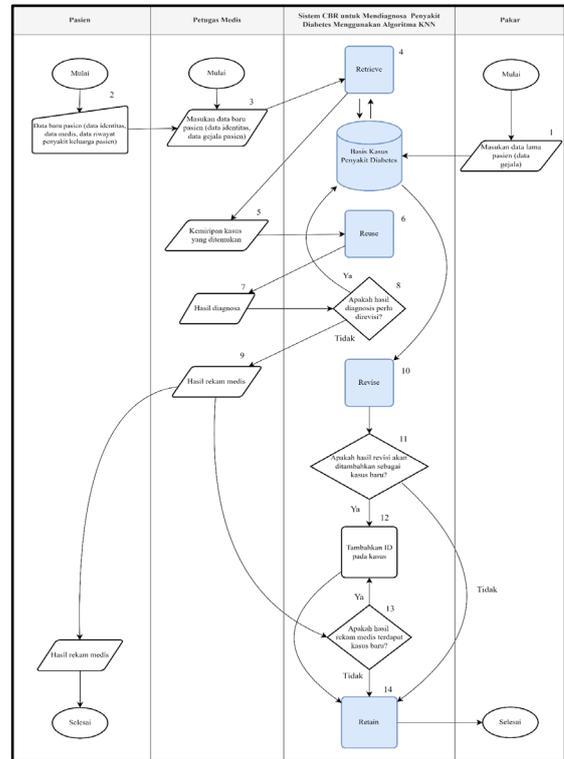
Keterangan:

S = Similarity (nilai kemiripan), yaitu 1 (sama) dan 0 (beda)  
W = Weight (bobot gejala)

**D. Tahap Perancangan Sistem CBR**

Dalam pembuatan sistem untuk mendiagnosa diabetes menggunakan Case Based Reasoning (CBR), dilakukan perancangan yang terperinci untuk setiap proses yang dijalankan oleh sistem dan pengguna. Gbr. 1 menunjukkan alur aktivitas sistem CBR. Proses dimulai dengan pakar memasukkan data gejala dari dataset ke dalam sistem,

membentuk basis kasus penyakit diabetes. Ketika pasien ingin di diagnosis, mereka mengisi data identitas, medis, dan riwayat penyakit diabetes keluarga. Petugas medis memasukkan data ini ke dalam sistem, yang kemudian membandingkannya dengan kasus lama. Jika ditemukan kemiripan kasus, sistem menggunakan data lama tersebut untuk menghitung hasil diagnosis pasien. Rekam medis diberikan kepada pasien jika hasilnya tidak memerlukan revisi. Jika tingkat kemiripan kurang dari 80%, pakar merevisi kasus tersebut. Jika kemiripan 80% atau lebih, hasil diagnosis tidak direvisi [13].



Gambar. 1 Diagram Aktivitas Sistem CBR Diagnosis Penyakit Diabetes

**III. HASIL DAN PEMBAHASAN**

**A. Pembahasan**

Dalam implementasi sistem CBR dan algoritma yang digunakan, ditentukan nilai bobot (weight) gejala dan nilai similarity (kemiripan antara fitur dan kasus) yang disamaratakan menjadi nilai biner antara 0 atau 1 berdasarkan rata-rata antar fitur dalam dataset. Jika nilai fitur kasus yang dihitung lebih besar dari nilai rata-rata, maka nilai similarity menjadi 1; jika tidak, nilai similarity menjadi 0. Hasil penentuan bobot dan rata-rata tersebut disajikan pada Tabel 2

TABEL II  
NILAI BOBOT DAN RATA-RATA GEJALA

Fitur Gejala	Weight	Mean
Pregnancies	0.7	4
Glucose	0.9	121

Blood Pressure	0.5	69
Skin Thickness	0.8	21
Insulin	0.9	80
BMI	0.6	32
Diabetes Pedigree Function	0.5	0.47
Age	0.9	33

Dalam proses perhitungan dan prediksi, dilakukan dengan menghitung bobot yang diterapkan pada masing-masing fitur untuk memberikan tingkat penting yang berbeda dalam perhitungan kesamaan (*similarity*). Kemudian, hasil dari nilai *similarity* akan diurutkan dengan urutan menurun, selanjutnya dilakukan pemilihan sejumlah K tetangga terdekat dari data pengujian dan pelatihan dari nilai *similarity* berdasarkan jarak Euclidean, yang dimana nilai *similarity* dengan kelas mayoritas dari nilai K tetangga tersebut akan dipilih dan nilai kemiripan yang paling besar akan menjadi hasil akhir. Selain itu, proses perhitungan, pembuatan model dan pengujian dilakukan dengan menggunakan bahasa pemrograman Python yang dijalankan di lingkungan pengembangan Google Colab.

## B. Tampilan Sistem

Hasil implementasi tampilan sistem dirancang menjadi GUI (*Graphical User Interface*) dengan menggunakan *framework* Qt bahasa pemrograman C++ yang dapat dijalankan di *desktop*. Aplikasi *desktop* ini diintegrasikan dengan Python dengan menggunakan mekanisme *IPC* (*Inter-Process Communication*) dengan menggunakan *unix domain socket*. Aplikasi yang diimplementasikan menggunakan Python untuk bertindak sebagai *server* yang akan mengelola pemrosesan data, *modelling* dan menghitung hasil prediksi. Sedangkan aplikasi GUI bertindak sebagai *client*. Hasil dari implementasi GUI adalah sebagai berikut.

### 1) Tampilan Menu Diagnosis:

Gambar. 2 Menu Diagnosis

Pada Gbr. 2, yaitu menu Diagnosis terdapat 3 jenis input data yang berisi *User Information* (Nama, Alamat, Umur, Jenis Kelamin, *Checkbox* Hamil, Berat badan, dan Tinggi badan), kemudian *Medical Data* (Jumlah Kehamilan, Kadar Glukosa, Tekanan Darah, Ketebalan Kulit, Insulin, BMI (yang dihitung dari hasil *user information*), dan *Diabetes Pedigree Function*) dan *Family Diseases* yang berisi jumlah keluarga, seperti kakek nenek, saudara, dan orang tua yang terjangkit penyakit serupa untuk menghasilkan nilai *Diabetes Pedigree Function*.

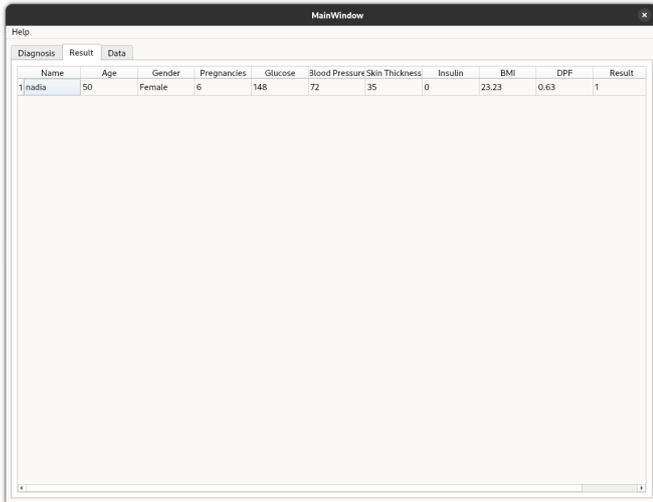
### 2) Tampilan Hasil Diagnosis:

Gambar. 3 Hasil Diagnosis saat Terkena Diabetes

Gambar. 4 Hasil Diagnosis saat Tidak Terkena Diabetes

Tampilan Hasil Diagnosis akan muncul setelah menekan tombol Start Diagnosis di menu Diagnosis. Di bagian atas tampilan di Gbr. 3 dan Gbr. 4 ini akan diberikan hasil yang menunjukkan apakah pengguna terkena penyakit diabetes atau tidak.

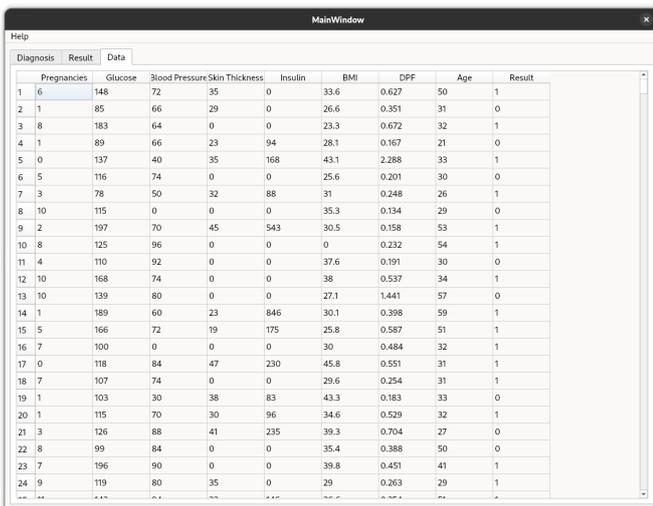
3) Tampilan Menu Hasil Prediksi:



Gambar. 5 Tampilan Menu Hasil Prediksi

Pada Gbr. 5 merupakan tempat dimana setiap data yang dimasukkan di menu diagnosis dan hasil dari diagnosis di tampilan Gbr. 3 dan 4 yang ditunjukkan dengan angka 1 jika pengguna terkena penyakit Diabetes.

4) Tampilan Menu Data:



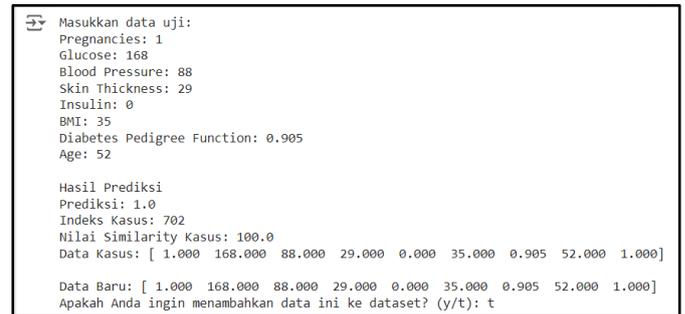
Gambar. 6 Tampilan Menu Data

Pada Gbr. 6, tampilan menu data adalah kumpulan kasus-kasus yang berisi data pengguna dan menjadi *dataset* yang dimana dilatih kembali jika terdapat kasus baru sehingga menghasilkan hasil prediksi kasus yang lebih banyak dan akurat.

C. Pengujian Sistem

Pengujian sistem dilakukan guna mengukur kinerja atau melakukan perhitungan nilai keakuratan sistem dalam mendiagnosa diabetes. Pada pengujian ini, *dataset* akan dibagi

menjadi data *training* dan *testing* dengan masing-masing kasus diabetes dan non-diabetes. Proses pengujian pertama dilakukan dengan memasukkan kasus baru dengan gejala yang sama persis dengan gejala yang terdapat pada data *training*. Nilai similarity kasus yang didapat adalah 100% seperti pada Gbr. 7.



Gambar. 7 Hasil Pengujian Pertama

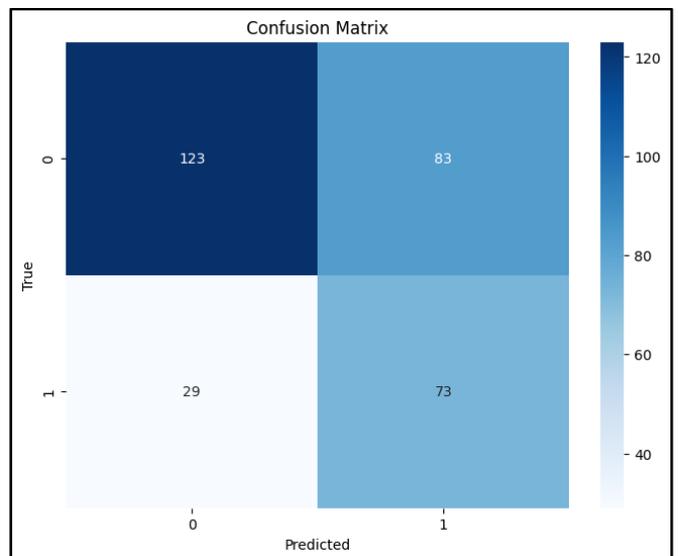
Kemudian, pada proses pengujian kedua dilakukan dengan menghitung nilai *accuracy*, *precision*, *f1-score*, *recall* dan *confusion matrix* dengan 3 skenario pengujian pada Tabel 3.

TABEL III  
PEMBAGIAN DATA LATIH DAN UJI

Skenario	Data Training	Data Testing	Total Data
1	60%	40%	308
2	70%	30%	231
3	80%	20%	154

Pada tiap skenario memiliki total data serta pembagian data latih dan uji yang berbeda tersebut menghasilkan nilai pengujian sebagai berikut.

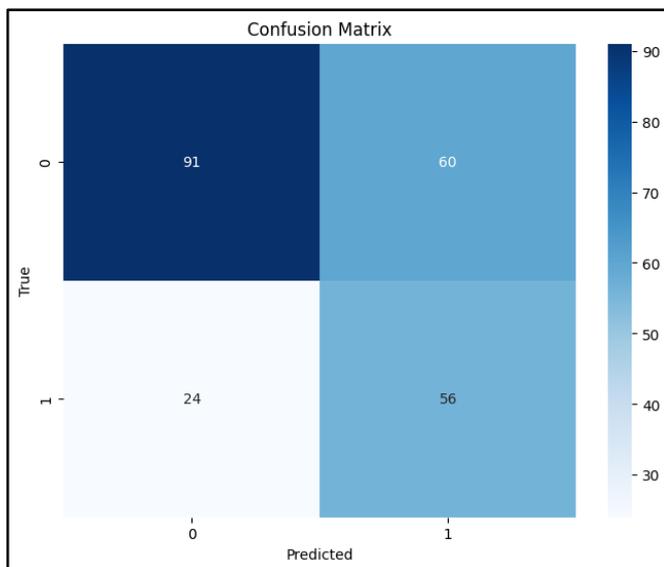
1) Hasil Skenario 1:



Gambar. 8 Hasil Confusion Matrix Skenario 1

Dari hasil skenario 1, *confusion matrix* pada Gbr. 8 menunjukkan bahwa dari total 308 data di set pengujian, terdapat 123 prediksi *True Negative* (TN), 83 prediksi *False Positive* (FP), 29 prediksi *False Negative* (FN), dan 73 prediksi *True Positive* (TP). Berdasarkan laporan evaluasi model, diperoleh bahwa model memiliki akurasi sekitar 63.64%, yang berarti sekitar 63.64% dari prediksi secara keseluruhan adalah benar. Presisi model, yang menunjukkan persentase prediksi positif yang benar, adalah sekitar 63.86%. Ini juga sejalan dengan *recall* model, yang menunjukkan bahwa sekitar 63.86% dari keseluruhan kasus positif dalam *dataset* telah diidentifikasi dengan benar oleh model. *F1-score*, yang menggabungkan presisi dan *recall*, adalah sekitar 69% untuk kelas 0 (tidak terkena diabetes) dan sekitar 57% untuk kelas 1 (terkena diabetes). Laporan klasifikasi menunjukkan bahwa presisi, *recall*, dan *f1-score* untuk kedua kelas memiliki keseimbangan yang baik, menunjukkan kemampuan model untuk mengidentifikasi kedua kelas dengan proporsi yang relatif serupa.

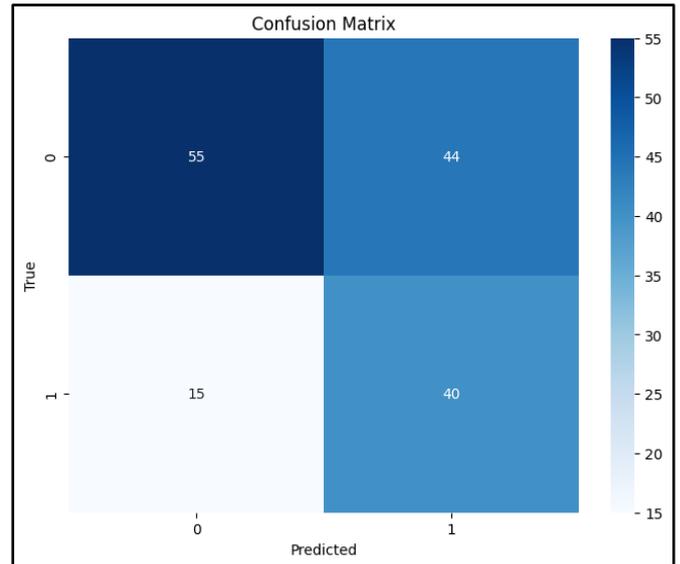
### 2) Hasil Skenario 2:



Gambar. 9 Hasil *Confusion Matrix* Skenario 2

Dari hasil skenario 2, *confusion matrix* pada Gbr. 9 menunjukkan bahwa dari total 231 data di set pengujian, terdapat 91 prediksi *True Negative* (TN), 60 prediksi *False Positive* (FP), 24 prediksi *False Negative* (FN), dan 56 prediksi *True Positive* (TP). Dalam evaluasi model untuk Skenario 2, ditemukan bahwa nilai akurasi, presisi, dan *recall* hampir identik dengan yang diperoleh dalam Skenario 1, dengan masing-masing nilai sekitar 63.64%, 63.70%, dan 65.13%. Meskipun proporsi data pelatihan dan pengujian berbeda dari yang digunakan di Skenario 1, metrik evaluasi menunjukkan bahwa model tetap memiliki performa yang relatif konsisten, bahkan ketika proporsi data pelatihan dan pengujian bervariasi. Konsistensi dalam hasil evaluasi ini menunjukkan bahwa model *K-Nearest Neighbor* yang digunakan mampu mengatasi variasi dalam data dan tetap mempertahankan tingkat akurasi, presisi dan *recall* yang serupa.

### 3) Hasil Skenario 3:



Gambar. 10 Hasil *Confusion Matrix* Skenario 3

Dari hasil skenario 3, *confusion matrix* pada Gbr. 10 menunjukkan bahwa dari total 154 data di set pengujian, terdapat 55 prediksi *True Negative* (TN), 44 prediksi *False Positive* (FP), 15 prediksi *False Negative* (FN), dan 40 prediksi *True Positive* (TP). Dalam Skenario 3, di mana 80% data digunakan untuk pelatihan dan 20% untuk pengujian, ditemukan bahwa akurasi model sedikit lebih rendah daripada dua skenario sebelumnya, yaitu sekitar 61.69%. Namun, presisi, *recall*, dan *f1-score* untuk kedua kelas, baik kelas 0 (tidak terkena diabetes) maupun kelas 1 (terkena diabetes), memiliki nilai yang cukup seimbang. Meskipun akurasi sedikit berkurang, keseragaman dalam presisi, *recall*, dan *f1-score* menunjukkan bahwa model memiliki kemampuan yang stabil dalam mengidentifikasi kedua kelas, meskipun menggunakan proporsi data yang berbeda untuk pelatihan dan pengujian.

## IV. KESIMPULAN

*Dataset* yang digunakan pada penelitian ini sebanyak 768 sampel, dimana 500 sampel adalah kasus non-diabetik sementara 268 lainnya adalah diabetik. Berdasarkan hasil *penelitian case based reasoning* menggunakan algoritma *K-Nearest Neighbor* dari pengujian kedua pada ketiga skenario pengujian yang telah dilakukan, dapat disimpulkan bahwa meskipun terdapat perbedaan dalam proporsi data pelatihan dan pengujian, nilai-nilai pada matrik evaluasi dengan nilai akurasi, presisi, *recall* dan *f1-score* menunjukkan konsistensi relatif dalam kinerja model serta jumlah memiliki pengaruh dalam hasil akurasi model. Hasil skenario 1 dan 2 menunjukkan performa yang relatif serupa dengan akurasi 63.64% dan presisi serta *recall* sekitar 63-65%, sementara skenario 3 menunjukkan sedikit penurunan dalam akurasi menjadi sekitar 61.99%. Namun, keseragaman dalam presisi, *recall*, dan *f1-score* untuk kedua kelas menunjukkan bahwa model memiliki kemampuan yang stabil dalam mengklasifikasikan kasus positif dan negatif, meskipun menggunakan proporsi data yang berbeda. Oleh karena itu, dapat disimpulkan bahwa model memiliki kinerja

yang cukup baik dan dapat diandalkan dalam mengklasifikasikan kasus terkait diabetes, meskipun perlu mempertimbangkan variasi dalam proporsi data pelatihan dan pengujian yang menyebabkan penurunan nilai akurasi yang dimana memerlukan penambahan dan pembagian data yang lebih tepat.

#### UCAPAN TERIMA KASIH

Terima kasih kami sampaikan kepada Ibu Dosen Made Hanindia Prami Swari selaku pengajar mata kuliah *Case Based Reasoning* yang telah membimbing kami dan pihak-pihak yang telah membantu dalam menyelesaikan penelitian ini.

#### REFERENSI

- [1] Yudianto, K., Rizmadewi, H., & Maryati, "IMPLEMENTASI CASE BASE REASONING PADA SISTEM PAKAR DALAM MENENTUKAN JENIS GANGGUAN KEJIWAAN," J-ICON : Jurnal Komputer dan Informatika., Vol.7, hal. 124 - 128, Okt. 2019
- [2] Retnowati, R., & Pujiyanta, A., "IMPLEMENTASI CASE BASE REASONING PADA SISTEM PAKAR DALAM MENENTUKAN JENIS GANGGUAN KEJIWAAN," Jurnal Sarjana Teknik Informatika., Vol. 1, hal. 70-78, Jun. 2013
- [3] Rahman, H. A., "Sistem Pakar dalam Mendeteksi Kerusakan Laptop dengan Metode Case Based Reasoning," Jurnal Sistem Informasi dan Teknologi., Vol.2, hal. 71-76, Sept. 2020.
- [4] Josefa, R., Sovia, R., & Mandala, "Sistem Pakar Diagnosa Penyakit Pneumonia Pada Anak Menggunakan Metode Case Based Reasoning," Seminar Nasional Teknologi Komputer & Sains (SAINTEKS), hal. 868-872, Jan. 2019.
- [5] Hozairi, Anwar, & Alim, S., "IMPLEMENTASI ORANGE DATA MINING UNTUK KLASIFIKASI KELULUSAN MAHASISWA DENGAN MODEL K-NEAREST NEIGHBOR, DECISION TREE SERTA NAIVE BAYES," Jurnal Ilmiah NERO., Vol. 6, hal. 133-144, 2021.
- [6] Nuraeni, N., "Klasifikasi Data Mining untuk Prediksi Potensi Nasabah dalam Membuat Deposito Berjangka," Jurnal Ilmiah Intech : Information Technology Journal of UMUS., Vol. 3, hal. 65-75, Mei. 2021.
- [7] Smith, J. W., Everhart, J. E., Dickson, W. C., Knowler, W. C., & Johannes, R. S. (1988, November). Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. In *Proceedings of the annual symposium on computer application in medical care* (p. 261). American Medical Informatics Association.
- [8] Salmin, M., & Hartati, S. (2018). Case Based Reasoning untuk Diagnosis Penyakit Infeksi Saluran Pernapasan Akut. *JIKO (Jurnal Informatika dan Komputer)*, 1(1), 21-26.
- [9] Leake, D., Ye, X., & Crandall, D. J. (2021, March). Supporting Case-Based Reasoning with Neural Networks: An Illustration for Case Adaptation. In *AAAI Spring Symposium: Combining Machine Learning with Knowledge Engineering* (Vol. 2).
- [10] Mubarak, A., & Muis, A. (2020). Case-Based Reasoning (CBR) Untuk Aplikasi Pemilihan Pesticida Hama Padi Berbasis Web. *JIKO (Jurnal Informatika dan Komputer)*, 3(2), 119-124.
- [11] Andika, R. (2019). Sistem Pakar Mendiagnosa Virus Pada Udara Vannamei Dengan Implementasi Metode CBR (Case-Based Reasoning) Dan Certainty Factor. *Pelita Informatika: Informasi dan Informatika*, 8(2), 248-253.
- [12] Akmal, F., & Winiarti, S. (2014). Sistem pakar untuk mendiagnosa penyakit lambung dengan implementasi metode CBR (Case-Based Reasoning) berbasis web. *Jurnal Sarjana Teknik Informatika e-ISSN*, 2338, 5197.
- [13] Atok, E. T., Sina, D. R., & Sihotang, D. M. Implementation Of Case Based Reasoning For Diagnosing Tuberculosis Disease Using K-nearest Neighbor. *Jurnal Komputer dan Informatika*, 7(2), 124-128.
- [14] Nas, C., & Kusnadi, K. (2019). Sistem Pakar Diagnosa Penyakit Gigi Dan Mulut Menggunakan Metode Case-Based Reasoning. *Jurnal Digit: Digital of Information Technology*, 9(2), 202-214.
- [15] Isna, F. N., Riana, F., Al Ikhsan, S. H., & Hermanto, C. (2022). Sistem Pakar Diagnosis Penyakit dan Hama Tanaman Pisang Menggunakan Case Based Reasoning. *Krea-TIF: Jurnal Teknik Informatika*, 10(1), 41-50.