



ISSN : 2339 - 1871

BETRIK BESEMAH TEKNOLOGI INFORMASI & KOMPUTER

Editor Office : Pusat Penelitian & Pengabdian Pada Masyarakat
(PPPM) ITPA

Phone : 0857-9716-9578

email : betriktpa@itpa.ac.id

Klasifikasi Indikasi Penyakit Jantung Pada Manusia Menggunakan Algoritma Fuzzy KNN

Kgs. M. Ammar Yazid¹, Dedy Hermanto²

Fakultas Ilmu Komputer dan Rekayasa, Program Studi Informatika, Universitas Multi Data
Palembang, Palembang, Indonesia^{1,2}

Sur-el : *kgsmaryazid@mhs.mdp.ac.id¹, dedy@mdp.ac.id²

Penulis Korespondensi: Kgs. M. Ammar Yazid, kgsmaryazid@mhs.mdp.ac.id

Abstrak: Tingginya angka kematian akibat penyakit jantung di Indonesia sebagian besar disebabkan oleh keterlambatan diagnosis, yang bersumber dari rendahnya kesadaran masyarakat untuk melakukan pemeriksaan awal. Keterbatasan terhadap informasi kesehatan yang akurat semakin memperparah kondisi ini, menciptakan kesenjangan kritis antara timbulnya penyakit dan penanganan medis. Penelitian ini mengusulkan pengembangan model klasifikasi untuk deteksi dini penyakit jantung menggunakan algoritma *Fuzzy K-Nearest Neighbor (Fuzzy KNN)*. Metode ini dipilih karena kemampuannya dalam mengindikasikan penderita penyakit jantung atau tidak serta mengelola ketidakpastian pada data gejala penyakit, dengan tujuan memberikan rekomendasi awal yang dapat meningkatkan kewaspadaan masyarakat. Pengujian kinerja model dilakukan secara cermat menggunakan metode *k-fold cross-validation* untuk memastikan hasil yang valid. Hasil penelitian menunjukkan adanya sebuah pertukaran (*trade-off*) yang signifikan. Pada nilai $k = 9$, model berhasil mencapai nilai *recall* sebesar 0.64. Namun, pencapaian ini disertai dengan nilai presisi pada 0.23 serta akurasi rata-rata sekitar 0.75. Meskipun demikian, *Fuzzy KNN* terbukti sangat berpotensi sebagai deteksi dini karena kemampuannya yang tinggi dalam meminimalkan risiko terlewatnya pasien.

Kata kunci : Deteksi Dini, *Fuzzy KNN*, Klasifikasi, *K-Fold Cross Validation*, Penyakit Jantung

Abstract: The high mortality rate from heart disease in Indonesia is largely caused by delayed diagnosis, which stems from low public awareness regarding early screenings. Limited access to accurate health information exacerbates this situation, creating a critical gap between disease onset and medical intervention. This research proposes the development of a classification model for the early detection of heart disease using the *Fuzzy K-Nearest Neighbor (Fuzzy KNN)* algorithm. This method was chosen for its ability to indicate whether an individual has heart disease and to manage the uncertainty within symptom data, aiming to provide an initial recommendation that can increase public awareness. The model's performance was rigorously evaluated using *k-fold cross-validation* to ensure valid results. The findings show a significant *trade-off*. At a k -value of 9, the model achieved a *recall* of 0.64. However, this was accompanied by a precision of 0.23 and an average accuracy of approximately 0.75. Nevertheless, *Fuzzy KNN* shows significant potential as an early detection tool due to its strong capability in minimizing the risk of missed patients (*false negatives*).

Keywords: Classification, Early Detection, *Fuzzy KNN*, Heart Disease, *K-Fold Cross Validation*

Received: 10-07-2025 | Accepted: 14-07-2025 | Published Online: 30-08-2025

All author: KGS. M. Ammar Yazid, Dedy Hermanto

1. PENDAHULUAN

Penyakit jantung merupakan penyebab utama kematian di seluruh dunia dan salah satu masalah kesehatan global yang paling penting. Di Indonesia, prevalensi penyakit jantung telah meningkat hingga 1,5% di semua kelompok umur, dengan 11 provinsi bahkan memiliki angka yang lebih tinggi daripada rata-rata nasional [1]. Menurut data, jumlah kematian akibat penyakit jantung koroner meningkat setiap tahunnya, dengan perkiraan 11 juta kematian pada tahun 2020 [2]. Menurut proyeksi, penyakit jantung dan pembuluh darah akan menyebabkan 17,7 juta kematian akibat Penyakit Tidak Menular (PTM) pada tahun 2030, atau 45% dari seluruh kematian [3]. Penyakit ini disebabkan oleh kondisi tidak normal jantung dan pembuluh darah yang dapat mengancam langsung kehidupan dan kesehatan manusia [4]. Tingginya angka kematian ini menunjukkan bahwa penanganan penyakit jantung di Indonesia sangatlah sulit. Penyakit jantung diperparah oleh sejumlah faktor risiko, termasuk diabetes, obesitas, hipertensi, dan pilihan gaya hidup yang buruk yang dapat diubah [5]. Selain itu, beberapa faktor risiko, seperti diabetes, tekanan tinggi, hiperkolesterolemia, sering merokok, dan tidak aktif, dapat diubah, sementara faktor risiko lainnya, seperti usia dan jenis kelamin, tidak dapat diubah [6]. Tingginya angka kematian ini berakar pada masalah krusial, yaitu keterlambatan dalam diagnosis. Banyak pasien tidak menyadari kondisi mereka karena gejala awal seringkali dianggap ringan dan tidak mengganggu aktivitas harian [7]. Kesenjangan antara timbulnya penyakit dan penanganan medis ini diperparah oleh terbatasnya akses masyarakat terhadap informasi kesehatan yang akurat (Ari Bianto, 2019). Padahal, banyak faktor risiko seperti hipertensi dan gaya hidup yang dapat dikendalikan jika terdeteksi lebih dini [5].

Seiring kemajuan teknologi, berbagai pendekatan komputasi telah dieksplorasi untuk membantu diagnosis medis. Penelitian sebelumnya telah menerapkan sistem pakar seperti *Case-Based Reasoning* (CBR), yang memiliki kelemahan dalam menangani kasus baru [8]. Pendekatan *Artificial Neural Network* (ANN) adalah cara lain untuk mengkategorikan penyakit jantung [9], serta algoritma *Naïve Bayes* dalam penambangan data untuk klasifikasi penyakit jantung koroner [10]. Untuk klasifikasi risiko, beberapa teknik pembelajaran mesin seperti *K-Nearest Neighbors* (KNN) telah menunjukkan hasil yang menjanjikan [11], sementara logika *Fuzzy* menunjukkan performa superior dalam mengelola ketidakpastian data gejala medis dengan tingkat error sangat rendah [12]. Tinjauan ini menunjukkan bahwa meskipun setiap metode memiliki keunggulan, ada peluang besar untuk inovasi dengan menggabungkan metode dalam mendeteksi penyakit jantung. Salah satu solusinya adalah penggunaan kombinasi metode klasifikasi yang menggabungkan *fuzzy* dan KNN, yaitu metode *Fuzzy KNN*. Metode ini menghasilkan perkiraan untuk data uji menggunakan nilai derajat keanggotaan saat ini dan memanfaatkan hasil terbesar berdasarkan semua data uji untuk setiap kelas sebagai penentu hasil [13].

Penelitian ini mengusulkan tentang klasifikasi orang dengan gejala penyakit jantung atau tidak menggunakan algoritma *Fuzzy K-Nearest Neighbors* (*Fuzzy KNN*) untuk rekomendasi awal bagi seseorang mengetahui dirinya mengalami gejala penyakit jantung atau tidak.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan dataset tabular berjudul *Heart Disease Health Indicators* dataset dari platform Kaggle (<https://www.kaggle.com/datasets/alexteboul/heart-disease-health-indicators-dataset>) yang berfungsi sebagai data awal untuk pembangunan model klasifikasi. Terdapat 254.000 data pemeriksaan awal penyakit jantung. Terdiri dari 22 atribut kolom yang dapat dilihat pada Tabel 1.

Tabel 1. Atribut Dataset

No	Nama Atribut	Tipe Data	Deskripsi Isi
1	<i>HeartDisseaseorAttack</i>	Biner	0 = ya, 1 = tidak (Class)
2	<i>HighBP</i>	Biner	0 = Tekanan darah tidak tinggi, 1 = Tekanan dara tinggi
3	<i>HighChol</i>	Biner	0 = Kolesterol tidak tinggi, 1 = Kolesterol tinggi
4	<i>CholCheck</i>	Biner	0 = Tidak cek kolesterol (5 thn), 1 = Pernah cek kolesterol
5	<i>BMI</i>	Numerik	Indeks Massa Tubuh (Body Mass Index)
6	<i>Smoker</i>	Biner	0 = Bukan perokok, 1 = Perokok
7	<i>Stroke</i>	Biner	0 = Tidak pernah stroke, 1 = Pernah stroke
8	<i>Diabetes</i>	Ordinal	0 = Tidak, 1 = Pra-diabetes, 2 = Diabetes
9	<i>PhysActivity</i>	Biner	0 = Tidak ada aktivitas fisik, 1 = Ada aktivitas fisik
10	<i>Fruits</i>	Biner	0 = Tidak konsumsi buah $\geq 1x$ sehari, 1 = Ya
11	<i>Veggies</i>	Biner	0 = Tidak konsumsi sayur $\geq 1x$ sehari, 1 = Ya
12	<i>HvyAlcoholConsump</i>	Biner	0 = Bukan peminum berat, 1 = Peminum berat
13	<i>AnyHealthcare</i>	Biner	0 = Tidak punya asuransi, 1 = Punya asuransi
14	<i>NoDocbcCost</i>	Biner	0 = Tidak ada kendala biaya, 1 = Ada kendala biaya
15	<i>GenHlth</i>	Ordinal	1=Sangat Baik, 2=Baik, 3=Cukup, 4=Kurang, 5=Buruk
16	<i>MenHlth</i>	Numerik	Jumlah hari dengan kesehatan mental buruk (1-30)
17	<i>PhysHlth</i>	Numerik	Jumlah hari dengan kesehatan fisik buruk (1-30)
18	<i>DiffWalk</i>	Biner	0 = Tidak kesulitan berjalan, 1 = Kesulitan berjalan
19	<i>Sex</i>	Biner	0 = Perempuan, 1 = Laki-laki
20	<i>Age</i>	Ordinal	Kategori usia 13 tingkat (1=18-24, ..., 13=80+)
21	<i>Education</i>	Ordinal	Tingkat pendidikan (skala 1-6)
22	<i>Income</i>	Ordinal	Tingkat pendapatan (skala 1-8)

2.1 Fuzzy KNN

Dengan menerapkan derajat keanggotaan pada himpunan, logika *fuzzy* memperluas konsep penalaran benar/salah. Dalam linguistik, "*fuzzy*" mengacu pada sesuatu yang ambigu, tidak jelas, tidak pasti, atau abu-abu. *Fuzzy* merupakan salah satu bentuk representasi pengetahuan yang sesuai dengan keadaan humanis yang bersifat spesifik konteks dan tidak mungkin dijawab secara tepat [14].

Algoritma KNN dikenal sebagai salah satu metode klasifikasi yang fundamental karena kesederhanaannya namun tetap menunjukkan performa yang tangguh dan efektif. Ide dasar algoritma ini adalah mengkategorikan item baru menurut mayoritas kelas dari set pelatihan yang paling dekat dengan objek atau memiliki properti yang paling mirip [15].

Teknik klasifikasi yang menggabungkan *fuzzy* dan KNN disebut *fuzzy KNN*. Pendekatan ini memprediksi data uji menggunakan nilai derajat keanggotaan saat ini dan memanfaatkan hasil

terbesar berdasarkan semua data uji untuk setiap kelas sebagai penentu hasil [13]. Data latih dan uji dimasukkan untuk digunakan dalam proses klasifikasi *fuzzy* KNN, yang memulai proses komputasi metode *fuzzy* KNN. Nilai K tetangga terdekat kemudian dihitung. Fungsi jarak *Euclidean* kemudian digunakan pada data latih dan uji untuk menghitung jarak. [16]. Persamaan (1) digunakan untuk menghitung jarak menggunakan jarak *Euclidean*.

$$d_i = \sqrt{\sum_{i=1}^p (x_{2i} - x_{1i})^2} \quad (1)$$

Keterangan:

x_{1i} = Komponen ke- i dari data *vector* x_1

x_{2i} = Komponen ke- i dari data *vector* x_2

p = Dimensi ruang

d_i = Jarak dua euclidean antara dua titik x_1 dan x_2

$(x_{2i} - x_{1i})^2$ = Selisih kuadrat antara komponen ke- i dari dua vektor

i = Variabel data

Menghitung *Fuzzy KNN* juga ada perhitungan data latih untuk menentukan kelas data yang direpresentasikan pada Persamaan (2).

$$u_{ij} = \begin{cases} 0.51 + \frac{n_j}{n} * 0.49, & \text{Jika } j = i \\ \frac{n_j}{n} * 0.49, & \text{Jika } j \neq i \end{cases} \quad (2)$$

Keterangan:

u_{ij} = Derajat keanggotaan data ke- i terhadap kelas/*cluster* ke- j .

u_i = Jumlah data yang termasuk ke dalam kelas/*cluster* ke- j (misalnya dari hasil klasifikasi sebelumnya).

u = Derajat keanggotaan data ke- i terhadap kelas/*cluster* ke- j .

u_{ij} = Jumlah total data.

Jika $j = I$ = Artinya cluster yang sedang di evaluasi adalah *cluster* sebenarnya (target).

Jika $j \neq I$ = Artinya *cluster* bukan targetnya.

Proses perhitungan terakhir pada metode *Fuzzy KNN* untuk menentukan keanggotaan setiap kelas. Persamaan (3) merupakan perhitungan keanggotaan setiap kelas.

$$\mu_i(x) = \frac{\sum_{j=1}^k u_{ij} (\|X - X_j\|^{-2})}{\sum_{j=1}^k (\|X - X_j\|^{-2})} \quad (3)$$

Keterangan:

$\mu_i(x)$ = Derajat keanggotaan dari data x terhadap cluster ke- i .

u_{ij} = Derajat keanggotaan data ke- i terhadap kelas/cluster ke- j .

X_j = Titik data ke- j (dalam dataset).

k = Jumlah total data (atau jumlah cluster, tergantung konteks).

x = Data yang sedang dihitung keanggotaannya.

2.2 K-Fold Cross-Validation

Validasi silang *K-fold* adalah salah satu teknik untuk menilai reliabilitas model. Validasi ini dilakukan dengan membagi data menjadi beberapa bagian (K) dan menggunakan satu bagian sebagai data latih dan bagian lainnya sebagai data uji secara bergantian hingga semua bagian teruji [17].

2.3 SMOTE

Analisis awal terhadap dataset target menunjukkan adanya permasalahan ketidakseimbangan kelas (*class imbalance*). Dari total data, kelas 'Tidak Terkena Penyakit Jantung' mendominasi sebesar 90,6%, sementara kelas 'Terkena Penyakit Jantung' hanya sebesar 9,4%. Karena kecenderungannya untuk memprediksi kelas mayoritas secara lebih akurat, kondisi ini dapat menimbulkan bias ke dalam model klasifikasi. Oleh karena itu, diterapkan teknik penanganan data dengan *oversampling* menggunakan metode SMOTE untuk menciptakan data sintesis pada kelas minoritas sehingga proporsi kedua kelas menjadi seimbang.

Teknik resampling yang disebut *Synthetic Minority Oversampling Technique* (SMOTE) diciptakan khusus untuk mengatasi ketidakseimbangan kelas dalam kumpulan data. Untuk meningkatkan ukuran populasi kelas minoritas, strategi ini mensintesis data palsu baru yang fiturnya diambil dari sampel saat ini. [18].

2.4 Evaluasi Hasil Klasifikasi

Pendekatan *Fuzzy KNN* digunakan untuk menilai kinerja klasifikasi berdasarkan hasil kategorisasi penyakit jantung. Nilai presisi, *recall*, dan skor F1 digunakan sebagai alat ukur dalam evaluasi penelitian ini. Jumlah nilai positif benar (TP), negatif benar (TN), negatif palsu (FN), dan positif palsu (FP) menentukan nilai-nilai ini secara keseluruhan. Nilai-nilai ini dapat dihitung dengan menggunakan Persamaan (4), (5), dan (6).

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$F1 - Score = 2 \times \frac{Precision \times recall}{precision + recall} \times 100\% \quad (6)$$

Keterangan:

TP: *True Positive* adalah jumlah data positif yang terklasifikasi dengan benar oleh sistem.

- TN: *True Negative* adalah jumlah data negatif yang terklasifikasi dengan benar oleh sistem.
 FN: *False Negative* adalah jumlah data negatif yang terklasifikasi dengan salah oleh sistem.
 FP: *False Positive* adalah jumlah data positif yang terklasifikasi dengan salah oleh sistem.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Tiga skenario nilai-k digunakan untuk pengujian dalam investigasi ini. Nilai-k yang digunakan adalah K-5, K-7, dan K-9. Skenario *k-fold* dengan total 10 fold dijalankan pada setiap pengujian. Tabel 2 menampilkan hasil pengujian dengan nilai k-5.

Tabel 2. Hasil Pengujian Nilai K-5

No	Fold	Akurasi	Precision	Recall	F1-Score
1	Fold-1	0.7838	0.23	0.56	0.33
2	Fold-2	0.7804	0.23	0.56	0.32
3	Fold-3	0.7815	0.23	0.56	0.32
4	Fold-4	0.7830	0.23	0.56	0.33
5	Fold-5	0.7778	0.23	0.57	0.33
6	Fold-6	0.7830	0.23	0.57	0.33
7	Fold-7	0.7809	0.23	0.55	0.32
8	Fold-8	0.7854	0.23	0.57	0.33
9	Fold-9	0.7807	0.23	0.56	0.32
10	Fold-10	0.7819	0.23	0.56	0.33
Rata-rata		0.7818	0.23	0.56	0.33

Dilihat pada Tabel 3, pengujian dengan nilai K-5 dan dari sepuluh *fold* yang dijalankan, model menunjukkan kinerja yang sangat stabil, dengan rata-rata akurasi akhir sebesar 0.7818. Pada evaluasi untuk kelas minoritas (*Heart Disease*), terlihat bahwa nilai recall bervariasi dalam rentang yang sangat sempit, antara 0.55 hingga 0.57, dengan rata-rata akhir 0.56. Sementara itu, nilai presisi secara konsisten berada di angka 0.23 di seluruh *fold*. Keseimbangan antara kedua metrik ini menghasilkan *F1-Score* rata-rata sebesar 0.33.

Tabel 3. Hasil Pengujian Nilai K-7

No	Fold	Akurasi	Precision	Recall	F1-Score
1	Fold-1	0.7703	0.23	0.62	0.34
2	Fold-2	0.7673	0.23	0.61	0.33
3	Fold-3	0.7648	0.23	0.60	0.33
4	Fold-4	0.7672	0.23	0.61	0.33
5	Fold-5	0.7651	0.23	0.62	0.33
6	Fold-6	0.7687	0.23	0.62	0.34
7	Fold-7	0.7654	0.23	0.59	0.32
8	Fold-8	0.7701	0.23	0.62	0.34
9	Fold-9	0.7673	0.23	0.62	0.33
10	Fold-10	0.7671	0.23	0.61	0.33
Rata-rata		0.7673	0.23	0.61	0.33

Hasil pengujian untuk model dengan $k=7$ dapat dilihat pada Tabel 3. Pada konfigurasi ini, terjadi pergeseran kinerja di mana rata-rata akurasi sedikit menurun menjadi 0.7673. Namun, hal ini diimbangi dengan peningkatan signifikan pada metrik *recall* untuk kelas 'Heart Disease', yang kini mencapai rata-rata 0.61. Nilai *recall per-fold* bervariasi antara 0.59 hingga 0.62, menunjukkan peningkatan kemampuan model dalam menjaring kasus positif dibandingkan dengan konfigurasi $k=5$. Nilai presisi tetap stabil di sekitar 0.23, menghasilkan *F1-Score* rata-rata 0.33, yang menandakan adanya perbaikan keseimbangan berkat peningkatan *recall*.

Tabel 4. Hasil Pengujian Nilai K-9

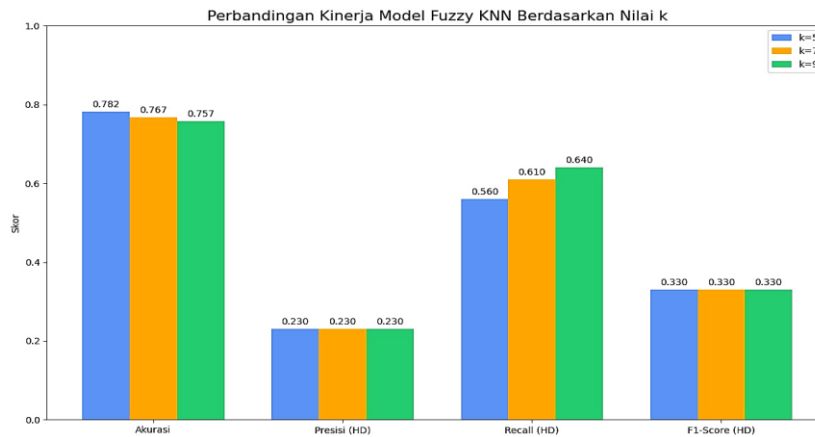
No	Fold	Akurasi	Precision	Recall	F1-Score
1	Fold-1	0.7605	0.23	0.65	0.34
2	Fold-2	0.7577	0.23	0.64	0.33
3	Fold-3	0.7557	0.22	0.64	0.33
4	Fold-4	0.7566	0.22	0.64	0.33
5	Fold-5	0.7553	0.22	0.65	0.33
6	Fold-6	0.7584	0.23	0.65	0.34
7	Fold-7	0.7561	0.22	0.63	0.33
8	Fold-8	0.7580	0.23	0.64	0.33
9	Fold-9	0.7563	0.23	0.65	0.33
10	Fold-10	0.7561	0.22	0.64	0.33
Rata-rata		0.7571	0.23	0.64	0.33

Pada Tabel 4 menampilkan rincian kinerja untuk konfigurasi $k=9$. Sesuai dengan pola yang teridentifikasi, peningkatan lebih lanjut nilai k kembali menurunkan rata-rata akurasi menjadi 0.7571. Konfigurasi ini berhasil mencapai nilai *recall* tertinggi di antara semua skenario, dengan rata-rata 0.64 untuk kelas 'Heart Disease'.

Hal ini menegaskan bahwa model menjadi semakin sensitif dalam mendeteksi kelas minoritas seiring dengan penambahan jumlah tetangga yang dipertimbangkan. Meskipun demikian, peningkatan *recall* ini tidak disertai dengan perbaikan pada nilai presisi, yang tetap berada di sekitar 0.23. Akibatnya, *F1-Score* rata-rata tidak menunjukkan peningkatan yang berarti dibandingkan dengan konfigurasi $k=7$.

3.2 Pembahasan

Dari hasil pengujian yang disajikan pada Gambar 1, terlihat sebuah pola kinerja yang sangat jelas pada model *Fuzzy KNN*. Ada sebuah pertukaran (*trade-off*) antara akurasi dengan kemampuan model dalam mendeteksi kasus 'Heart Disease'. Semakin tinggi nilai k yang digunakan, dari 5 hingga 9, rata-rata akurasi memang cenderung menurun dari 0.7818 menjadi 0.7571. Namun di sisi lain, nilai *recall* untuk kelas 'Heart Disease' justru meningkat secara konsisten, dari 0.56 pada $k=5$ hingga mencapai puncaknya di 0.64 pada $k=9$. Ini menunjukkan bahwa dengan mempertimbangkan lebih banyak tetangga, model menjadi lebih baik kasus positif yang sebenarnya, sehingga risiko melewatkan pasien sakit dapat dikurangi.



Gambar 1. Grafik Hasil Pengujian

Meskipun *recall* meningkat, tantangan utama yang terungkap dari Gambar di atas adalah nilai presisi yang tidak bergerak dari angka 0.23. Artinya, walaupun model semakin banyak menemukan pasien sakit, jumlah atau tebakan yang salah juga ikut bertambah secara proporsional. Hal ini mengindikasikan bahwa masalahnya bukan pada pemilihan *k*, melainkan pada karakteristik data itu sendiri yang kemungkinan memiliki fitur yang sangat mirip antara kelas sehat dan sakit, sehingga sulit untuk dibedakan.

4. KESIMPULAN

Hasil pengujian pada penelitian ini menunjukkan bahwa algoritma ini berhasil diterapkan untuk memprediksi penyakit jantung, namun dengan sebuah pertukaran (*trade-off*). Di satu sisi, peningkatan nilai *k* secara konsisten menaikkan nilai *recall*, yang mengindikasikan bahwa model menjadi lebih andal dalam mengidentifikasi individu yang benar-benar menderita penyakit jantung. Di sisi lain, tantangan terbesar yang ditemukan adalah nilai presisi yang rendah di angka 0.23, yang menunjukkan bahwa model juga menghasilkan prediksi keliru dalam jumlah besar, di mana individu sehat sering kali diklasifikasikan sebagai penderita.

Berdasarkan analisis *cross-validation* dengan 10 *fold*, konfigurasi dengan $k = 9$ menunjukkan hasil terbaik di antara semua skenario yang diuji. Meskipun akurasinya sedikit lebih rendah (0.7571) dibandingkan nilai *k* yang lain, $k = 9$ berhasil mencapai *recall* tertinggi dengan rata-rata 0.64. Ini menegaskan bahwa model pada konfigurasi ini paling sensitif dan paling efektif dalam mendeteksi kasus penyakit jantung yang sebenarnya.

Dengan demikian, bahwa $k = 9$ merupakan pilihan optimal dalam penelitian ini, terutama jika tujuan utamanya adalah untuk memaksimalkan deteksi kasus positif (*recall*), meskipun harus menerima konsekuensi tingginya jumlah presisi rendah. Oleh karena itu, dapat disimpulkan bahwa *fuzzy KNN* memiliki potensi sebagai deteksi dini karena kemampuannya dalam memaksimalkan identifikasi kasus.

DAFTAR RUJUKAN

- [1] A. P. Sari, G. Rahmadini, H. Charlina, Z. E. Pradani, and M. I. Ramadan, "Analisis Masalah Kependudukan Di Indonesia," *Journal of Economic Education*, vol. 2, no. 1, pp. 29–37, 2023.
- [2] L. I. Sahara and R. Adelina, "Analisis Asupan Lemak Terhadap Profil Lemak Darah Berkaitan Dengan Kejadian Penyakit Jantung Koroner (PJK) di Indonesia: Studi Literatur," *Jurnal Pangan Kesehatan dan Gizi Universitas Binawan*, vol. 1, no. 2, pp. 48–60, 2021.
- [3] N. D. P. Budiono, N. E. W. Budianto, Z. Inayah, and S. KM, *Epidemiologi Penyakit Tidak Menular*. PT. Penerbit Qriset Indonesia, 2023.
- [4] Ratnasari, A. Jurnaidi Wahidin, A. Eko Setiawan, and P. Bintoro, "Machine Learning Untuk Klasifikasi Penyakit Jantung," *Aisyah Journal Of Informatics and Electrical Engineering (A.J.I.E.E)*, vol. 6, no. 1, pp. 145–150, Feb. 2024, doi: 10.30604/jti.v6i1.272.
- [5] W. S. Naomi, I. Picauly, and S. M. Toy, "Faktor Risiko Kejadian Penyakit Jantung Koroner," *Media Kesehatan Masyarakat*, vol. 3, no. 1, pp. 99–107, 2021.
- [6] A. Cahyati, S. Februanty, and S. Adini, "Deteksi Dini Tekanan Darah Dan Kadar Gula Darah Sebagai Pencegahan Kegawatdaruratan Penyakit Jantung," *ABDIMAS: Jurnal Pengabdian Masyarakat*, vol. 4, no. 1, pp. 594–599, Apr. 2021, doi: 10.35568/abdimas.v4i1.1053.
- [7] A. Rahmat, M. Syafiih, and M. Faid, "Implementasi Klasifikasi Potensi Penyakit Jantung Dengan Menggunakan Metode C4.5 Berbasis Website (Studi Kasus Kaggle.com)," *INFOTECH journal*, vol. 9, no. 2, pp. 393–400, 2023.
- [8] D. Dona, H. Maradona, and M. Masdewi, "Sistem Pakar Diagnosa Penyakit Jantung Dengan Metode Case Based Reasoning (CBR)," *ZONasi: Jurnal Sistem Informasi*, vol. 3, no. 1, pp. 1–12, 2021.
- [9] D. Pradana, M. L. Alghifari, M. F. Juna, and D. Palaguna, "Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network," *Indonesian Journal of Data and Science*, vol. 3, no. 2, pp. 55–60, 2022.
- [10] A. F. Riany and G. Testiana, "Penerapan Data Mining untuk Klasifikasi Penyakit Jantung Koroner Menggunakan Algoritma Naïve Bayes," in *MDP Student Conference*, 2023, pp. 297–305.
- [11] D. A. Ryfai, N. Hidayat, and E. Santoso, "Klasifikasi Tingkat Resiko Serangan Penyakit Jantung menggunakan Metode K-Nearest Neighbor," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 10, pp. 4701–4707, 2022.
- [12] S. Sumiati, H. T. Sigit, A. Triayudi, and M. Theresia, "Diagnosa Kelainan Jantung dengan Pendekatan Fuzzy Logic Mamdani," *TELKA-Jurnal Telekomunikasi, Elektronika, Komputasi dan Kontrol*, vol. 8, no. 2, pp. 149–157, 2022.
- [13] N. Siburian, I. Cholissodin, and P. P. Adikara, "Penerapan Metode Fuzzy K-Nearest Neighbor pada Klasifikasi Penyakit Menular Seksual Pria," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 11, pp. 4096–4102, 2020.
- [14] A. J. Rindengan and Y. A. R. Langi, "Sistem Fuzzy," *Bandung: CV. Patra Media Grafindo*, 2019.
- [15] M. Mentari, Y. A. Sari, and R. K. Dewi, "Deteksi Kanker Kulit Melanoma dengan Linear Discriminant Analysis-Fuzzy k-Nearest Neighbour Lp-Norm," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 2, no. 1, p. 34, Jan. 2016, doi: 10.26594/r.v2i1.443.
- [16] F. Ramadhani, A. Satria, and I. P. Sari, "Implementasi Metode Fuzzy K-Nearest Neighbor dalam Klasifikasi Penyakit Demam Berdarah," *Hello World Jurnal Ilmu Komputer*, vol. 2, no. 2, pp. 58–62, 2023.
- [17] Agung Nugroho and Agit Amrullah, "Evaluasi Kinerja Algoritma K-NN Menggunakan K-Fold Cross Validation pada Data Debitur KSP Galih Manunggal," *Jurnal Informatika Teknologi dan Sains (Jinteks)*, vol. 5, no. 2, pp. 294–300, May 2023, doi: 10.51401/jinteks.v5i2.2506.
- [18] K. Pramayasa, I. M. D. Maysanjaya, and I. G. A. A. D. Indradewi, "Analisis Sentimen Program Mbkm Pada Media Sosial Twitter Menggunakan KNN Dan SMOTE," *SINTECH (Science and Information Technology) Journal*, vol. 6, no. 2, pp. 89–98, 2023.