

COMPARATIVE PERFORMANCE ANALYSIS OF K-NEAREST NEIGHBORS AND BINARY LOGISTIC REGRESSION IN CLASSIFICATION HEART DISEASE RISK BASED ON CLINICAL FACTORS*

ANALISIS PERBANDINGAN KINERJA METODE K-NEAREST NEIGHBORS DAN REGRESI LOGISTIK BINER DALAM KLASIFIKASI RISIKO PENYAKIT JANTUNG BERDASARKAN FAKTOR KLINIS

Najwa Febryla Adyta^{1‡}, Fayra Shabrina Madjid¹, Ghonia Choirinnajdhatul Muna¹, and Septian Rahardiantoro¹

¹Statistics and Data Science Study Program, IPB University, Indonesia

[‡]corresponding author: najwaafebryla@apps.ipb.ac.id

Copyright © 2026 Najwa Febryla Adyta, Fayra Shabrina Madjid, Ghonia Choirinnajdhatul Muna, and Septian Rahardiantoro. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Heart disease is one of the leading causes of death worldwide, making accurate classification methods essential for supporting early disease risk detection. Although K-Nearest Neighbors (KNN) and Binary Logistic Regression have been widely used, studies comparing both methods using consistent preprocessing procedures and threshold tuning remain limited. This study aims to compare the performance of the KNN and Binary Logistic Regression using the Heart Disease Dataset from the UCI Machine Learning Repository, consisting of 270 observations and 13 predictor variables. The analysis included data preprocessing, outlier handling using the IQR method, Min-Max normalization for KNN, threshold optimization using Youden's J index, and model evaluation using accuracy, precision, sensitivity, specificity, F1-Score, and AUC. The results showed that KNN with $k = 23$ achieved the best overall performance, with an accuracy of 0.83, specificity of 0.91, precision of 0.87, F1-score of 0.79, and AUC of 0.86. In comparison, Binary Logistic Regression achieved an accuracy of 0.78 and an AUC of 0.82, but achieved a higher sensitivity of 0.75 compared to 0.72 for KNN. Overall, KNN outperformed Binary Logistic Regression on most evaluation metrics, whereas Binary Logistic Regression was more suitable when minimizing undetected heart disease cases was the primary objective.

Keywords: Binary Logistic Regression, Classification, Heart Disease, K-Nearest Neighbors

Abstrak

Penyakit jantung merupakan salah satu penyebab kematian tertinggi di dunia, sehingga diperlukan metode klasifikasi yang akurat untuk mendukung deteksi dini risiko penyakit. Meskipun metode K-Nearest Neighbors (KNN) dan Regresi Logistik Biner telah banyak digunakan, perbandingan kedua metode dengan prosedur *preprocessing* dan *threshold tuning* yang konsisten masih terbatas. Penelitian ini bertujuan membandingkan kinerja metode KNN dan Regresi Logistik Biner menggunakan *Heart Disease Dataset* dari UCI Machine Learning Repository yang terdiri atas 270 observasi dan 13 peubah prediktor. Analisis dilakukan melalui *pre-processing* data, penanganan outlier menggunakan metode IQR, normalisasi Min-Max pada KNN, serta penentuan *threshold* optimal menggunakan Youden's J Index dan evaluasi model menggunakan akurasi, presisi, sensitivitas, spesifisitas, F1-score, dan AUC. Hasil penelitian menunjukkan bahwa KNN dengan $k = 23$ memberikan performa terbaik secara umum, dengan akurasi 0.83, spesifisitas 0.91, presisi 0.87, F1-score 0.79, dan AUC 0.86. Sementara itu, Regresi Logistik Biner menghasilkan akurasi 0.78 dan AUC 0.82, tetapi memiliki sensitivitas yang lebih tinggi, yaitu 0.75 dibandingkan KNN sebesar 0.72. Secara keseluruhan, KNN unggul pada sebagian besar metrik evaluasi, sedangkan Regresi Logistik Biner lebih sesuai ketika prioritas utama adalah meminimalkan kasus pasien sakit yang tidak terdeteksi.

Kata Kunci: Klasifikasi, K-Nearest Neighbors, Penyakit Jantung, Regresi Logistik Biner

1. Pendahuluan

Penyakit jantung merupakan salah satu penyebab kematian tertinggi di dunia akibat gangguan fungsi jantung dalam memompa darah ke seluruh tubuh secara optimal (Ryfai et al., 2022). Berdasarkan laporan World Health Organization (WHO) pada tahun 2022, penyakit kardiovaskular menyebabkan sekitar 19.8 juta kematian setiap tahun atau setara dengan 32% dari total kematian global, dengan sekitar 85% diantaranya disebabkan oleh penyakit jantung dan stroke. Tingginya angka kejadian tersebut dipengaruhi oleh berbagai faktor risiko klinis seperti merokok, kurangnya aktivitas fisik, pola makan tidak sehat, kadar kolesterol yang tinggi, diabetes, tekanan darah tinggi, serta obesitas (Arini dan Umam, 2021).

Perkembangan teknologi dan sistem rekam medis digital memungkinkan data klinis pasien dianalisis menggunakan metode statistika dan *machine learning* untuk membangun model klasifikasi risiko penyakit jantung. Metode klasifikasi banyak digunakan untuk mengelompokkan pasien ke

dalam kategori berisiko tinggi atau rendah berdasarkan karakteristik klinis yang dimiliki. Regresi Logistik dan K-Nearest Neighbors (KNN) merupakan dua metode yang sering digunakan dalam permasalahan klasifikasi biner dan memiliki pendekatan yang berbeda, sehingga dapat menghasilkan tingkat performa yang bervariasi pada dataset yang berbeda.

Beberapa penelitian terdahulu menunjukkan hasil yang beragam dalam klasifikasi penyakit jantung. Penelitian oleh Wijaya (2024) menunjukkan bahwa SVM memiliki performa yang lebih unggul dan stabil dibandingkan metode Decision Tree, sedangkan penelitian oleh Surbakti *et al.* (2025) menemukan bahwa KNN memiliki tingkat akurasi yang lebih tinggi dibandingkan Regresi Logistik Biner, meskipun perbedaan performanya tidak signifikan secara statistik. Selain itu, penelitian oleh Ryfai *et al.* (2022) menunjukkan bahwa metode K-Nearest Neighbors (KNN) mampu memberikan hasil klasifikasi penyakit jantung yang baik dengan tingkat akurasi mencapai 96.67%. Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada perbandingan banyak metode klasifikasi secara bersamaan, sehingga pembahasan mengenai karakteristik dan performa masing-masing metode belum dilakukan secara mendalam dan konsisten.

Perbedaan tahapan preprocessing, teknik validasi, penentuan *threshold* klasifikasi, dan metrik evaluasi pada penelitian sebelumnya menyebabkan hasil performa sulit dibandingkan secara objektif. Selain itu, kajian yang secara khusus membandingkan KNN dan Regresi Logistik masih terbatas, padahal kedua metode tersebut memiliki pendekatan klasifikasi yang berbeda. KNN merupakan metode berbasis kedekatan jarak yang sederhana dan efektif dalam menangani permasalahan kompleks, sedangkan Regresi Logistik menawarkan interpretasi model yang lebih jelas melalui hubungan linear antara peubah *input* dan *output* (Aryanti *et al.*, 2025). Oleh karena itu, penelitian ini membandingkan kinerja kedua metode menggunakan preprocessing yang seragam, penentuan parameter dan *threshold* optimal berbasis *10-fold cross-validation* serta Youden's J Index, dan evaluasi menggunakan akurasi, presisi, spesifisitas, sensitivitas, F1-score dan AUC untuk memperoleh model klasifikasi penyakit jantung yang paling optimal.

2. Metodologi

2.1 Data

Penelitian ini menggunakan *Heart Disease Dataset* dari UCI Machine Learning Repository. *Dataset* tersebut terdiri atas 270 observasi dengan 13 peubah prediktor dan 1 peubah respon (target: 1=Sakit, 0=Tidak Sakit). Peubah-peubah yang digunakan disajikan pada Tabel 1.

Tabel 1: Peubah yang digunakan

Peubah	Keterangan	Tipe data	Referensi
Y	Diagnosis penyakit jantung	Integer	Saniy <i>et al.</i> (2022)
X1	Usia pasien	Integer	Saniy <i>et al.</i> (2022)
X2	Jenis kelamin	Kategorik	Saniy <i>et al.</i> (2022)
X3	Jenis nyeri dada	Kategorik	Saniy <i>et al.</i> (2022)
X4	Tekanan darah saat istirahat	Integer	Saniy <i>et al.</i> (2022)
X5	Kadar kolesterol	Integer	Saniy <i>et al.</i> (2022)
X6	Kadar gula darah	Kategorik	Saniy <i>et al.</i> (2022)
X7	Kondisi ECG ketika istirahat	Kategorik	Saniy <i>et al.</i> (2022)
X8	Detak jantung maksimal	Integer	Saniy <i>et al.</i> (2022)
X9	Latihan yang diinduksi angina	Kategorik	Saniy <i>et al.</i> (2022)
X10	Depresi ST yang diinduksi olahraga	Integer	Saniy <i>et al.</i> (2022)
X11	Kemiringan puncak ST	Kategorik	Saniy <i>et al.</i> (2022)
X12	Jumlah pembuluh darah	Integer	Saniy <i>et al.</i> (2022)
X13	Kelainan darah	Kategorik	Saniy <i>et al.</i> (2022)

2.2 Metode Penelitian

Analisis dilakukan menggunakan perangkat lunak R dengan paket *readxl*, *dplyr*, *ggplot2*, *caret*, *class*, *pROC*, *ROCR*, *corrplot*, dan *ResourceSelection*. Tahapan penelitian yang dilakukan adalah sebagai berikut:

1. Melakukan *pre-processing* data dengan memeriksa *missing value*, mengonversi peubah respon dari numerik ke tipe faktor, serta menyeleksi peubah yang relevan untuk pemodelan.
2. Melakukan eksplorasi data menggunakan statistik deskriptif, visualisasi boxplot, serta analisis korelasi antar peubah numerik untuk memahami karakteristik data.
3. Melakukan pembagian data secara stratifikasi dengan proporsi 70:30 berdasarkan peubah respon.
4. Melakukan deteksi *outlier* menggunakan metode IQR pada data latih untuk mencegah data *leakage*. Peubah kategorik nominal dikonversi menjadi peubah *dummy* menggunakan `fullRank=TRUE` sehingga jumlah prediktor meningkat dari 13 menjadi 17 peubah (Wardhana *et al.*, 2025).
5. Melakukan pemodelan K-Nearest Neighbors (KNN) sebagai metode klasifikasi nonparametrik yang mengklasifikasikan observasi baru berdasarkan kelas mayoritas dari *k* tetangga terdekatnya menggunakan jarak Euclidean (Nugraha *et al.*, 2020):

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Seluruh peubah prediktor dinormalisasi ke rentang [0,1] menggunakan *Min-Max*: $x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$ (Bu'ulolo, 2024). Nilai k optimal ditentukan melalui *10-fold cross-validation* pada rentang $k = 1, 3, 5, \dots, 51$ dengan metrik AUC, sedangkan *threshold* optimal ditentukan menggunakan Youden's J Index (Wijiyanto et al., 2024). Potensi *overfitting* dievaluasi dengan membandingkan performa data latih dan uji (Tuntun et al., 2022).

6. Melakukan pemodelan Regresi Logistik Biner untuk memodelkan probabilitas terjadinya suatu kejadian ($Y=1$, Sakit) sebagai fungsi dari peubah prediktor (Alwi et al., 2018):

$$P(Y = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p)}} \quad (2)$$

Model penuh dibangun menggunakan 17 peubah hasil *dummy encoding* tanpa normalisasi karena Regresi Logistik tidak berbasis perhitungan jarak (Alwi et al., 2018; Rahmadani et al., 2023). Parameter diestimasi menggunakan *Maximum Likelihood Estimation* (MLE), kebaikan model dievaluasi dengan uji Hosmer-Lemeshow (*fit* jika $p\text{-value} > 0.05$) (Hafid et al., 2023; Surbakti et al., 2025), dan *threshold* optimal ditentukan melalui *10-fold cross-validation* menggunakan Youden's J Index.

7. Melakukan evaluasi model pada data uji menggunakan enam metrik performa yang dihitung berdasarkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) dari matriks konfusi, meliputi akurasi, sensitivitas, spesifisitas, presisi, F1-score, dan AUC (Surbakti et al., 2025).

Tabel 2: Metrik evaluasi yang digunakan

Metrik	Rumus	Keterangan
Akurasi	$\frac{TP + TN}{TP + TN + FP + FN}$	Proporsi prediksi benar keseluruhan
Sensitivitas	$\frac{TP}{TP + FN}$	Kemampuan deteksi kelas positif
Spesifisitas	$\frac{TN}{TN + FP}$	Kemampuan deteksi kelas negatif
Presisi	$\frac{TP}{TP + FP}$	Ketepatan prediksi positif
F1-Score	$2 \times \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}}$	<i>Harmonic mean</i> presisi & sensitivitas
AUC	Area di bawah kurva ROC	Kemampuan diskriminasi model

8. Melakukan perbandingan performa model K-Nearest Neighbors (KNN) dan Regresi Logistik Biner berdasarkan metrik evaluasi pada data uji, meliputi akurasi, sensitivitas, spesifisitas, presisi, F1-score, dan Area Under Curve (AUC), untuk menentukan model dengan kemampuan klasifikasi terbaik dalam mendeteksi penyakit jantung.

3. Hasil dan Pembahasan


3.1 Eksplorasi Data

Eksplorasi data dilakukan untuk mengidentifikasi karakteristik dan distribusi peubah respon pada dataset yang digunakan. Tabel 3 menunjukkan bahwa terdapat 150 pasien tidak sakit (55.56%) dan 120 pasien sakit (44.44%). Distribusi kelas yang relatif seimbang ini menunjukkan bahwa teknik penyeimbangan kelas tidak diperlukan. Setelah pembagian data secara stratifikasi 70:30, data latih terdiri atas 189 observasi dan data uji terdiri atas 81 observasi, dengan proporsi kelas yang identik pada kedua kelompok.

Tabel 3: Distribusi peubah target pada dataset, data latih, dan data uji

Data	Tidak sakit	Sakit	Total
Keseluruhan	150	120	270
Latih	105	84	189
Uji	45	36	81

Hasil eksplorasi peubah numerik menunjukkan adanya perbedaan pola antara pasien sakit dan tidak sakit. Detak jantung maksimum cenderung lebih rendah pada pasien sakit. Sebaliknya, kondisi jantung dan jumlah pembuluh darah cenderung lebih tinggi pada pasien sakit sehingga menunjukkan hubungan yang cukup kuat dengan status penyakit jantung. Sementara itu, usia dan tekanan darah memiliki distribusi yang relatif tumpang tindih antar kelas sehingga kurang diskriminatif dibandingkan peubah lainnya.



Gambar 1: Boxplot peubah numerik berdasarkan status penyakit jantung

Pada peubah kategorik, pola yang terlihat cukup menonjol terdapat pada jenis kelamin, jenis nyeri dada, latihan yang diinduksi angina, kemiringan puncak ST, dan kelainan darah. Proporsi pasien laki-laki mendominasi pada kelompok sakit dibandingkan pasien perempuan. Selain itu, jenis nyeri dada tertentu terlihat lebih sering muncul pada pasien sakit, sehingga peubah ini relevan secara klinis dalam klasifikasi penyakit jantung. Hasil korelasi juga menunjukkan tidak terdapat korelasi ekstrem antar prediktor, sehingga data masih layak digunakan untuk pemodelan Regresi Logistik Biner.

3.2 Hasil Pemodelan K-Nearest Neighbors

Pemodelan KNN dilakukan menggunakan data hasil *dummy encoding* dan normalisasi *Min-Max*. *Dummy encoding* diterapkan pada peubah kategorik nominal seperti jenis nyeri dada, kelainan darah, dan kemiringan puncak ST, sedangkan normalisasi *Min-Max* diperlukan karena KNN merupakan metode berbasis jarak yang sensitif terhadap perbedaan skala antar peubah. Pemilihan nilai k menggunakan *10-fold cross validation* dengan metrik ROC pada nilai k ganjil dari 1 hingga 51. Hasil *tuning* menunjukkan bahwa nilai k optimal adalah 23, dengan ROC sebesar 0.93, sensitivitas sebesar 0.88, dan spesifisitas sebesar 0.76 pada data latih, yang disajikan pada Tabel 4. Nilai $k = 23$ menunjukkan bahwa model mempertimbangkan kelompok tetangga yang cukup untuk menghasilkan klasifikasi lebih stabil, sehingga dapat mengurangi risiko *overfitting* yang umumnya terjadi pada nilai k yang terlalu kecil.

Tabel 4: Hasil *tuning* nilai k pada model KNN

k	ROC	Sensitivitas	Spesifisitas
10	0.91	0.87	0.78
21	0.92	0.87	0.76
23	0.93	0.88	0.76
25	0.92	0.88	0.77
27	0.92	0.87	0.76
31	0.92	0.88	0.79

Pada data uji, KNN dengan *threshold* optimal sebesar 0.59 menghasilkan *confusion matrix* seperti pada Tabel 5. Berdasarkan hasil tersebut, model berhasil mengklasifikasikan 41 pasien tidak sakit dengan benar dan 26 pasien sakit dengan benar. Namun, masih terdapat 10 pasien sakit yang diprediksi tidak sakit dan 4 pasien tidak sakit yang diprediksi sakit.

Tabel 5: *Confusion Matrix* KNN pada data uji dengan *Threshold* optimal

Prediksi	Aktual tidak sakit	Aktual sakit
Tidak Sakit	41	10
Sakit	4	26

Evaluasi potensi *overfitting* dilakukan dengan membandingkan performa model pada data latih dan data uji. Pada data latih, KNN dengan $k = 23$ menghasilkan akurasi sebesar 0.85, sensitivitas 0.80, dan spesifisitas 0.89. Dibandingkan dengan performa pada data uji (akurasi 0.83; sensitivitas 0.72; spesifisitas 0.91), terjadi sedikit penurunan performa pada data uji, terutama pada sensitivitas. Meskipun demikian, perbedaan performa antara data latih dan data uji relatif tidak besar sehingga model masih menunjukkan kemampuan generalisasi yang cukup baik terhadap data baru

3.3 Hasil Pemodelan Regresi Logistik Biner

Regresi Logistik Biner digunakan sebagai metode pembanding karena sesuai untuk klasifikasi dengan peubah respon biner. Berbeda dengan KNN yang bekerja berdasarkan kedekatan antar observasi, Regresi Logistik menghasilkan nilai probabilitas yang kemudian dikonversi menjadi kelas menggunakan nilai *threshold*. Pada analisis ini, model menggunakan data hasil *dummy encoding*, sedangkan normalisasi tidak dilakukan karena Regresi Logistik tidak berbasis perhitungan jarak.

Tabel 6: Kelayakan model dan *threshold* Regresi Logistik Biner

Aspek evaluasi	Indikator	Hasil
Kecocokan model	<i>Null deviance</i>	259.67
Kecocokan model	<i>Residual deviance</i>	78.10
Kecocokan model	AIC	114.10
<i>Goodness of fit</i>	Hosmer-Lemeshow <i>p-value</i>	0.99
Klasifikasi	<i>Cut-off default</i>	0.50
Klasifikasi	<i>Threshold optimal</i>	0.47

Berdasarkan Tabel 6, nilai residual deviance menurun dari 259.67 menjadi 78.10, yang menunjukkan bahwa penambahan peubah prediktor mampu meningkatkan kemampuan model dalam menjelaskan status penyakit jantung. Hasil uji Hosmer-Lemeshow menghasilkan *p-value* sebesar 0.99 sehingga model dinilai sesuai dengan data. Peubah yang signifikan dalam model meliputi jenis kelamin pasien (sex), jenis nyeri dada kategori 3 (cp.3), tekanan darah istirahat (rbp), kadar kolesterol (sc), kemiringan puncak ST kategori 1 (slope.1), jumlah pembuluh darah yang terdeteksi (mv), serta hasil pemeriksaan thalassemia kategori 2 (thal.2). Temuan tersebut menunjukkan keterkaitan antara beberapa peubah prediktor dengan risiko penyakit jantung yang telah banyak dilaporkan

dalam literatur medis. Peubah seperti tekanan darah istirahat, jumlah pembuluh darah yang terdeteksi, dan jenis nyeri dada menunjukkan relevansi klinis yang kuat terhadap risiko penyakit jantung. Regresi Logistik Biner juga memiliki keunggulan dalam mengidentifikasi pengaruh masing-masing peubah melalui nilai koefisien dan odds ratio, sehingga mampu memberikan interpretasi terhadap faktor-faktor risiko yang berkontribusi terhadap status penyakit jantung pasien.

Tabel 7: *Confusion Matrix* Regresi Logistik pada data uji (*Threshold* optimal 0.47)

Prediksi	Aktual tidak sakit	Aktual sakit
Tidak Sakit	36	9
Sakit	9	27

Pada *cut-off default* 0.5, Regresi Logistik menghasilkan akurasi sebesar 0.77, sensitivitas 0.72, spesifisitas 0.80, presisi 0.74, F1-score 0.73, dan AUC 0.82. Selanjutnya, dilakukan *threshold tuning* menggunakan *Youden's J* dari *10-fold cross validation* dan diperoleh *threshold* optimal sebesar 0.47. *Threshold* ini lebih rendah dari 0.5, model menjadi sedikit lebih sensitif dalam mengklasifikasikan pasien sebagai "Sakit". Setelah *threshold* optimal diterapkan pada data uji, diperoleh *confusion matrix* seperti pada Tabel 7. Berdasarkan hasil tersebut, model berhasil mengklasifikasikan 36 pasien tidak sakit dengan benar dan 27 pasien sakit dengan benar, dengan sensitivitas meningkat menjadi 0.75, akurasi 0.78, spesifisitas 0.80, presisi 0.75, F1-score 0.75, dan AUC 0.82.


3.4 Perbandingan Kinerja Model KNN dengan Regresi Logistik Biner

Perbandingan akhir dilakukan menggunakan hasil pada *threshold* optimal masing-masing model. Pada KNN, *threshold* optimal yang digunakan adalah 0.59, sedangkan pada Regresi Logistik Biner *threshold* optimal yang digunakan adalah 0.47. Pendekatan ini digunakan agar kedua model dibandingkan berdasarkan konfigurasi terbaik yang diperoleh dari proses *tuning*.

Tabel 8: Kinerja KNN dan Regresi Logistik Biner pada *Threshold* optimal

Metrik	KNN	Regresi Logistik Biner	Model lebih tinggi
Akurasi	0.83	0.78	KNN
Sensitivitas	0.72	0.75	Regresi Logistik
Spesifisitas	0.91	0.80	KNN
Presisi	0.87	0.75	KNN
F1-score	0.79	0.75	KNN
AUC	0.86	0.82	KNN

Berdasarkan Tabel 8, KNN unggul pada akurasi, spesifisitas, presisi, F1-score, dan AUC, yang menunjukkan performa klasifikasi lebih baik secara keseluruhan. Nilai spesifisitas KNN sebesar 0.91 menunjukkan kemampuan model dalam meminimalkan *false positive*, dengan 4 kasus dibandingkan 9 kasus pada Regresi Logistik Biner. Sebaliknya, Regresi Logistik Biner unggul pada sensitivitas sebesar 0.75 dibandingkan 0.72 pada KNN, sehingga lebih baik dalam meminimalkan *false negative*, dengan 9 kasus dibandingkan 10 kasus pada KNN. Meskipun selisih *false negative* kedua model relatif kecil, setiap kasus *false negative* tetap memiliki implikasi penting dalam konteks klinis. Hasil tersebut menunjukkan bahwa KNN lebih sesuai digunakan pada sistem skrining dengan prioritas meminimalkan *false positive*, sedangkan Regresi Logistik Biner lebih tepat digunakan apabila prioritas utama adalah meningkatkan sensitivitas deteksi dini penyakit jantung.



Gambar 2: Kurva ROC KNN dan Regresi Logistik Biner

Kurva ROC menunjukkan bahwa KNN memiliki kemampuan diskriminasi yang lebih baik dibandingkan Regresi Logistik Biner, ditunjukkan oleh nilai AUC yang lebih tinggi. Namun, Regresi Logistik menghasilkan sensitivitas yang sedikit lebih tinggi setelah *threshold* tuning. Hasil tersebut menunjukkan adanya *trade-off* antara sensitivitas dan spesifisitas dalam konteks deteksi dini penyakit jantung.

4. Simpulan dan Saran

Berdasarkan hasil analisis, metode K-Nearest Neighbors (KNN) dengan nilai $k = 23$ menunjukkan performa klasifikasi yang lebih tinggi dibandingkan Regresi Logistik Biner pada sebagian besar metrik evaluasi dalam mendukung deteksi dini risiko penyakit jantung. KNN unggul pada akurasi, spesifisitas, presisi, F1-score, dan AUC, sedangkan Regresi Logistik Biner menghasilkan sensitivitas yang lebih tinggi sehingga lebih baik dalam meminimalkan *false negative*. Hasil ini menunjukkan adanya *trade-off* antara sensitivitas dan spesifisitas pada klasifikasi medis. KNN lebih sesuai digunakan pada sistem skrining dengan prioritas performa

klasifikasi secara keseluruhan, sedangkan Regresi Logistik Biner lebih sesuai apabila prioritas utama adalah meningkatkan sensitivitas deteksi dini pasien berisiko. Selain itu, Regresi Logistik Biner memiliki keunggulan dalam interpretabilitas model melalui odds ratio untuk membantu analisis faktor risiko klinis.

Penelitian ini masih memiliki keterbatasan berupa ukuran dataset yang relatif kecil serta penggunaan dataset publik dari UCI Machine Learning Repository yang masih terbatas pada karakteristik populasi tertentu dan belum melalui validasi eksternal. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan data klinis primer dari fasilitas kesehatan di Indonesia agar hasil evaluasi model lebih representatif terhadap karakteristik populasi lokal serta mendukung implementasi sistem deteksi dini penyakit jantung pada konteks pelayanan kesehatan nasional. Penelitian ini juga memberikan kontribusi melalui penerapan *preprocessing*, *threshold optimization*, dan evaluasi multi-metrik yang konsisten pada kedua model.

Daftar Pustaka

- Alwi, W., Ermawati, & Husain, S. (2018). Analisis regresi logistik biner untuk memprediksi kepuasan pengunjung pada rumah sakit umum daerah Majene. *Jurnal Matematika dan Statistika serta Aplikasinya*, 6(1), 20–26. doi: 10.24252/msa.v6i1.4783. <https://doi.org/10.24252/msa.v6i1.4783>
- Arini, T., & Umam, F. N. (2021). Pengukuran lemak tubuh dan indeks massa tubuh sebagai upaya pencegahan resiko penyakit kardiovaskular. *Jurnal Bhakti Civitas Akademika*, 4(1), 25–30. <https://e-journal.lppmdianhusada.ac.id/index.php/jbca/article/view/164>
- Bu'ulolo, E. (2024). Algoritma K-Nearest Neighbor (K-NN) dengan normalisasi Max Min untuk menentukan calon mahasiswa yang layak menerima KIP Kuliah Merdeka. *Jurnal Sistem Informasi dan Sistem Komputer (SIMKOM)*, 9(2), 184–194. <https://e-jurnal.stmikbinsa.ac.id/index.php/simkom/article/view/445>
- Hafid, H., et al. (2023). Analisis regresi logistik biner pada data kesehatan. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 5(1), 15–22. <https://jurnalvariansi.unm.ac.id/index.php/variansi/article/view/71>
- Nugraha, A. R. D., Auliasari, K., & Pranoto, Y. A. (2020). Implementasi metode K-Nearest Neighbor (KNN) untuk seleksi calon karyawan baru (studi kasus: BFI Finance Surabaya). *Jurnal Mahasiswa Teknik Informatika*, 4(2), 14–20. doi: 10.36040/jati.v4i2.2656. <https://doi.org/10.36040/jati.v4i2.2656>

- Rahmadani, A. A., Putri, A. A., Happy, D. M., Julia, Dala, M. A. D., Angka, M. TD., Rafiq, M., & Wasono. (2023). Analisis regresi logistik biner untuk memprediksi faktor-faktor internal yang memengaruhi keharmonisan rumah tangga menurut provinsi di Indonesia pada tahun 2021. *Prosiding Seminar Nasional Matematika, Statistika, dan Aplikasinya*, 3(1), 116–127. <https://prosiding.msa.iainponorogo.ac.id>
- Ryfai, D. A., Hidayat, N., & Santoso, E. (2022). Klasifikasi tingkat risiko serangan penyakit jantung menggunakan metode K-Nearest Neighbor. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 6(10), 4701–4707. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/11525>
- Saniy, R. N., Sitorus, Y. T. S., Meyana, N. A., Najwa, S., Pravitasari, A. A., & Indrayatna, F. (2022). Penerapan algoritma K-Nearest Neighbor pada klasifikasi penyakit jantung. *Biostatistics Journal of Statistics Theory and Aplication*, 1(1), 222-229. doi: <https://doi.org/10.1234/bias.v2022i1.192>
- Surbakti, C. A., Sinaga, A. S., Simorangkir, A. M., Sarah, A. S., Harefa, C. J., & Dalimunthe, S. F. (2025). Perbandingan metode K-Nearest Neighbors (K-NN) dan regresi logistik biner dalam memprediksi kanker. *Indonesian Journal of Health Science*, 5(2), 321–333. doi: <https://doi.org/10.54957/ijhs.v5i2.1456>
- Tuntun, R., Kusriani, K., & Kusnawi. (2022). Analisis perbandingan kinerja algoritma klasifikasi dengan menggunakan metode K-Fold Cross Validation. *Jurnal Media Informatika Budidarma*, 6(4), 2111. doi: 10.30865/mib.v6i4.4681. <https://doi.org/10.30865/mib.v6i4.4681>
- Wardhana, A. D., et al. (2025). Model prediksi penyakit jantung dengan penanganan outlier menggunakan Interquartile Range dan Extreme Gradient Boosting. *Journal of Information System Research (JOSH)*. <https://ejurnal.seminar-id.com/index.php/josh/article/view/6390>
- Wijiyanto, et al. (2024). Teknik K-Fold Cross Validation untuk mengevaluasi performa model klasifikasi. *Jurnal Algoritma*, 21(1), 239–248. <https://jurnal.itg.ac.id/index.php/algoritma/article/view/1618>
- Wijaya, F. D. H. (2024). Analisis data penyakit jantung menggunakan algoritma decision tree dan support vector machines (SVM). *Jurnal Komputer dan Informatika*, 19(2), 156–163. doi: 10.36040/jati.v5i2.3738. <https://doi.org/10.36040/jati.v5i2.3738>