

Analisis Akurasi Algoritma K-Nearest Neighbor Untuk Diagnosis Penyakit Jantung Pada Lansia

David Sebastian Sipayung¹, Syarifah Atika²
^{1,2}Universitas Prima Indonesia

ABSTRACT

Penyakit jantung adalah salah satu penyebab utama kematian di dunia, terutama pada populasi lansia, yang sering kali sulit dideteksi pada tahap awal karena gejala yang tidak spesifik. Oleh karena itu, diperlukan metode diagnosis yang lebih cepat dan efisien, seperti penerapan algoritma pembelajaran mesin. Penelitian ini bertujuan untuk mengevaluasi akurasi algoritma K-Nearest Neighbor (KNN) dalam mendiagnosis penyakit jantung pada lansia, dengan menggunakan dataset yang diperoleh dari Kaggle dan terdiri dari 918 data pasien. Data tersebut disaring untuk usia lansia (60 tahun ke atas), menghasilkan 253 data yang digunakan dalam klasifikasi. Empat nilai k (3, 5, 7, dan 9) diuji untuk menentukan nilai k terbaik dalam mengklasifikasikan penyakit jantung. Hasil evaluasi menunjukkan bahwa model dengan k = 9 memiliki performa terbaik dengan nilai recall tertinggi (0.93) dan F1-Score sebesar 0.81, meskipun dengan akurasi yang sedikit lebih rendah (0.68). K = 5 memberikan keseimbangan terbaik antara precision (0.72) dan recall (0.85), dengan F1-Score 0.78. Berdasarkan hasil ini, K = 9 lebih efektif untuk aplikasi medis yang mengutamakan deteksi lebih banyak kasus positif, meskipun mengorbankan sedikit precision. Penelitian ini dapat memberikan kontribusi untuk pengembangan sistem diagnosis penyakit jantung yang lebih cepat, efisien, dan akurat pada lansia, dengan harapan dapat meningkatkan deteksi dini penyakit jantung.

Keywords: *penyakit jantung, lansia, K-nearest Neighbor, pembelajaran mesin.*

1. INTRODUCTION

Salah satu penyebab utama kematian di dunia terutama pada golongan usia lansia adalah penyakit jantung. Penyakit jantung merupakan salah satu penyakit termasuk penyakit yang berbahaya dan memerlukan penanganan yang cepat karena dapat muncul secara tiba-tiba pada penderitanya (Nawawi et al., 2019). Di Indonesia penyakit jantung merupakan penyebab kematian yang tertinggi menurut data Global Burden of Disease (GBD) dan Institute for Health Metrics and Evaluation (IHME) pada periode 2014-2019 (Kementrian Kesehatan Republik Indonesia, 2022). Usia lanjut merupakan salah satu faktor yang signifikan terhadap penyakit jantung (Melyani et al., 2023). Penyakit jantung pada lansia sering tidak dapat terdeteksi pada tahap awal, hal ini dikarenakan gejala yang tidak spesifik atau terabaikan sebagai bagian dari penuaan (Makarim, 2021).

Diagnosis penyakit jantung pada lansia menjadi lebih kompleks karena adanya variasi gejala yang sering kali tumpang tindih dengan kondisi medis lainnya. Hal ini menyebabkan keterlambatan dalam deteksi dan penanganan yang tepat waktu (Melyani et al., 2023). Ketergantungan pada metode diagnosis tradisional seperti pemeriksaan fisik, tes darah, atau pencitraan medis membutuhkan waktu, biaya, dan sumber daya yang signifikan, yang tidak selalu dapat diakses oleh semua kalangan, terutama di daerah terpencil (Laksono et al., 2024). Oleh karena itu diperlukan sebuah model yang dapat melakukan diagnosis penyakit jantung yang lebih cepat dan efisien.

Teknologi yang berkembang pesat saat ini, terutama bidang kecerdasan buatan (AI) dan pembelajaran mesin (machine learning), memungkinkan penerapan metode yang lebih cepat dan efisien dalam mendiagnosis penyakit jantung (Nuryani et al., 2023). Penggunaan algoritma untuk menganalisis data medis dapat membantu memprediksi penyakit dengan lebih akurat dan memberikan keputusan yang lebih cepat (Alariyibi et al., 2023). Salah satu algoritma yang populer untuk analisis data medis adalah K-Nearest Neighbor (KNN), yang dapat mengklasifikasikan data berdasarkan kedekatannya dengan data lain. KNN dikenal karena kesederhanaannya dan kemampuannya dalam menghasilkan hasil yang akurat dalam pengklasifikasian data berdasarkan pola-pola tertentu. Penggunaan KNN dalam diagnosis penyakit jantung memiliki potensi untuk meningkatkan akurasi prediksi, dengan memanfaatkan data karakteristik medis pasien lansia, seperti tekanan darah, kadar kolesterol, riwayat keluarga, dan faktor risiko lainnya (Akbarollah et al., 2023).

Tujuan dari penelitian ini adalah untuk mengevaluasi akurasi dari algoritma KNN dalam mendiagnosis penyakit jantung pada populasi lansia, dengan harapan dapat memberikan kontribusi terhadap pengembangan system diagnosis penyakit jantung yang lebih cepat, efisien dan akurat. Penelitian ini juga diharapkan dapat memberikan kontribusi dalam pengembangan sistem diagnosis penyakit jantung yang lebih cepat, efisien dan akurat pada pasien lansia.

2. LITERATURE REVIEW

(Akbarollah et al., 2023) melakukan penelitian mengenai penerapan algoritma K-Nearest Neighbor dalam klasifikasi penyakit jantung. Dalam penelitian tersebut, digunakan dataset yang terdiri dari 1024 rekaman pasien dengan 14 atribut, termasuk kelas. Hasil evaluasi menunjukkan bahwa model mencapai akurasi 92%, presisi 90%, dan recall 92%.

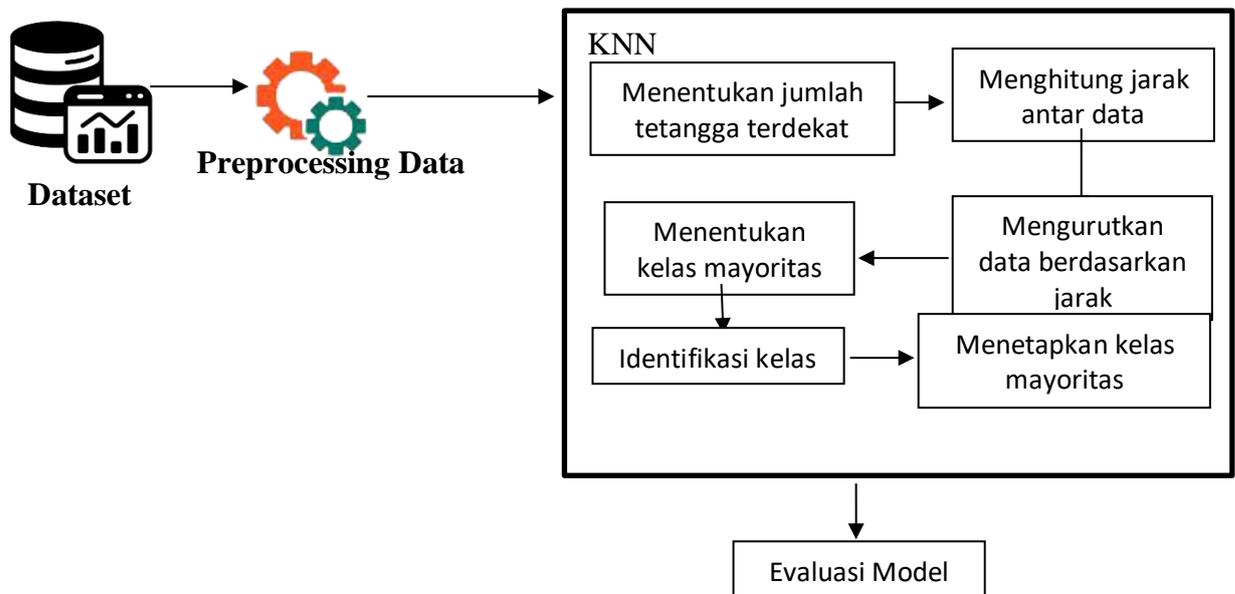
Penelitian yang dilakukan oleh Novitasari et al.. (2023) bertujuan untuk mengklasifikasikan penyakit jantung dengan menggunakan pendekatan SMOTE pada algoritma modified K-Nearest Neighbor. Data yang digunakan berasal dari repositori UCI dataset dengan 918 rekaman dan 12 atribut. Hasil penelitian menunjukkan bahwa algoritma MKNN dengan rasio 90:10 memperoleh akurasi sebesar 88,05%, sementara dengan penerapan SMOTE pada MKNN, akurasi meningkat menjadi 90,20%. Penerapan teknik SMOTE terbukti meningkatkan akurasi pada data dengan performa rendah.

Penelitian yang dilakukan oleh Hakimah & Muhimah, (2021), bertujuan untuk mengklasifikasikan penderita penyakit jantung menggunakan metode Naïve Bayes yang dipadukan dengan teknik chi-square untuk pemilihan atribut. Data yang digunakan dalam penelitian ini diambil dari Kaggle, dengan total 303 data. Hasil pengujian menunjukkan bahwa penerapan Naïve Bayes dengan Chi-square pada tingkat signifikansi 0,01 dapat meningkatkan akurasi dan presisi masing-masing sebesar 1% dan 5% dibandingkan metode Naïve Bayes tanpa pemilihan atribut. Namun, metode Naïve Bayes tanpa pemilihan atribut menunjukkan kinerja terbaik dalam hal recall dibandingkan dengan Naïve Bayes yang menggunakan Chi-square.

3. METHODS

- TAHAPAN PENELITIAN

Penelitian ini bertujuan untuk mengklasifikasikan penyakit jantung pada lansia dengan memanfaatkan algoritma KNN yang akan melalui serangkaian tahapan proses, dan dapat dilihat berikut ini.



Gambar 1. Tahapan Penelitian

Berikut penjelasan untuk gambar diatas:

1. Pengumpulan data

Langkah pertama pada penelitian ini adalah memilih dataset yang akan digunakan untuk melakukan analisis. Pada penelitian ini digunakan dataset yang diperoleh dari Kaggle yaitu heart.csv dengan jumlah data 918 dan atribut yang berjumlah 12 termasuk atribut class.

2. Preprocessing Data

Pada tahap ini dilakukan penanganan data-data yang tidak diperlukan seperti data yang tidak memiliki nilai (missing value), outlier, maupun imbalance data (Sepharni et al., 2022). Dataset yang digunakan dengan jumlah 918 data sebelum dilakukan seleksi usia lanjut yaitu usia dari 60 tahun keatas (Kemenkes, 2024) setelah dilakukan seleksi berdasarkan usia lanjut menjadi 253 data.

3. Klasifikasi KNN

Pada penelitian ini algoritma yang digunakan untuk klasifikasi adalah *K-Nearest Neighbor* (KNN). Dikarenakan dataset yang digunakan tidak besar maka nilai k yang digunakan adalah 3, 5, 7, 9 agar tidak kehilangan detail pola. Adapun Langkah-langkah perhitungan algoritma KNN (Maskuri et al., 2022):

- a. Menentukan jumlah tetangga terdekat (*k*) yang akan digunakan dalam klasifikasi. Dengan pemilihan nilai *k* yang tepat sangat memengaruhi kinerja dari algoritma KNN.
- b. Menghitung jarak antar data yang akan diklasifikasikan dengan semua data dalam *training set*. Metode yang umum digunakan untuk menghitung jarak adalah *Euclidean Distance* yang dirumuskan:

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

Dimana *x* dan *y* adalah dua titik data dan *n* adalah jumlah dari atribut.

- c. Mengurutkan semua data dalam *training set* berdasarkan jarak yang telah diperoleh dan selanjutnya memilih *k* data dengan jarak terdekat.
- d. Kemudian menentukan kelas mayoritas dengan cara mengidentifikasi kelas yang paling sering muncul (mayoritas) yang kemudian kelas ini akan menjadi prediksi kelas untuk data yang kita klasifikasikan.
- e. Selanjutnya menetapkan kelas mayoritas yang telah ditentukan sebagai hasil klasifikasi untuk data baru tersebut.

4. Evaluasi Model

Setelah klasifikasi dilakukan menggunakan algoritma KNN, tahap selanjutnya adalah evaluasi dengan menganalisis hasil yang diperoleh dari algoritma untuk memastikan kesesuaian antara hasil perhitungan dan tujuan penelitian. Proses validasi dilakukan untuk menilai kualitas klasifikasi dengan mengukur tingkat akurasi, presisi, dan recall. Berikut ini adalah rumus yang digunakan dalam proses validasi ini (Miller et al., 2024):

a. Accuracy

Akurasi dilakukan untuk mengukur seberapa sering model membuat prediksi dengan benar terhadap seluruh data yang diuji.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(2)$$

Dimana:

- TP = *True Positive* (prediksi positif yang benar)
- TN = *True Negative* (prediksi negatif yang benar)
- FP = *False Positive* (prediksi positif yang salah)
- FN = *False Negative* (prediksi negatif yang salah)

b. Precision

Presisi adalah pengukuran akurasi model dalam memprediksi kelas positif, Dimana dalam hal diagnosis penyakit serius nilai dari *false Negative* harus diminimalkan.

$$accuracy = \frac{TP}{TP+FP} \dots\dots\dots(3)$$

c. *Recall*

Sedangkan *recall* dilakukan untuk mengukur kemampuan dari model yang dibangun untuk menemukan semua kasus positif yang ada.

$$accuracy = \frac{TP}{TP+FN} \dots\dots\dots(4)$$

4. RESULTS

Model *K-Nearest Neighbor* (KNN) diuji dengan beberapa nilai *k* yaitu 3,5, 7 dan 9 dan hasil dari evaluasi model berdasarkan metrik *accuracy*, *precision*, *recall* dan *F1-Score* dapat dilihat pada tabel 1 dibawah ini.

Tabel 1. Hasil Evaluasi Model KNN

k	Accuracy	Precision	Recall	F1-Score
3	0,62	0,72	0,78	0,75
5	0,66	0,72	0,85	0,78
7	0,63	0,70	0,85	0,77
9	0,68	0,72	0,93	0,81

Dari hasil di atas, dapat kita lihat bahwa *k* = 9 memberikan Accuracy tertinggi, yaitu 0.68, yang menunjukkan performa terbaik dalam hal ketepatan prediksi secara keseluruhan. Recall pada *k* = 9 sangat tinggi (0.93), menunjukkan model sangat baik dalam mengidentifikasi kasus-kasus penyakit jantung (true positive). Walau Precision dan F1-Score untuk *k* = 9 sedikit lebih rendah daripada *k* = 5, model ini lebih baik dalam menemukan semua kasus positif meskipun ada kemungkinan sedikit lebih banyak prediksi yang salah.

Pada nilai *k* = 5 memberikan keseimbangan yang baik antara Precision (0.72) dan Recall (0.85), dengan F1-Score yang solid di 0.78, yang menjadikannya pilihan model yang baik ketika kita ingin menghindari kesalahan prediksi yang signifikan pada kedua kategori (positif dan negatif).

Accuracy mengukur persentase prediksi yang tepat dibandingkan dengan seluruh prediksi yang dilakukan. Untuk model *k* = 9, meskipun memiliki accuracy yang cukup baik (0.68), masih ada ruang perbaikan jika mempertimbangkan trade-off antara precision dan recall. Precision menunjukkan seberapa banyak dari hasil prediksi positif yang benar-benar positif. Nilai precision di setiap model hampir sama (sekitar 0.72), yang menunjukkan bahwa model cukup baik dalam memprediksi hasil positif yang benar. Recall mengukur kemampuan model dalam menemukan semua kasus positif. Dengan nilai recall tertinggi pada *k* = 9 (0.93), model ini sangat efisien dalam mendeteksi pasien dengan penyakit jantung, yang sangat penting dalam konteks medis di mana penting untuk tidak melewatkan pasien yang membutuhkan perhatian. F1-Score adalah rata-rata harmonik dari precision dan recall. Skor F1 yang lebih tinggi, seperti yang terlihat pada *k* = 9 (0.81), menunjukkan keseimbangan yang lebih baik antara precision dan recall, yang penting dalam aplikasi medis agar tidak terlalu sering salah dalam mendeteksi baik positif maupun negatif.

5. CONCLUSION

Berdasarkan hasil evaluasi, model dengan $K = 9$ memberikan performa terbaik dalam hal recall dan f1-score, meskipun sedikit mengorbankan akurasi dan precision. Jika tujuan utama adalah mengidentifikasi sebanyak mungkin pasien yang berisiko terkena penyakit jantung (dengan mengutamakan recall), maka $K = 9$ adalah pilihan terbaik. Namun, jika kita menginginkan keseimbangan yang lebih baik antara ketepatan dan kemampuan mendeteksi kasus positif, $K = 5$ adalah pilihan yang lebih baik. Dengan demikian, $K = 9$ sangat efektif untuk aplikasi medis di mana diagnosis yang lebih sensitif (mendeteksi lebih banyak pasien berisiko) lebih diutamakan, meskipun dengan sedikit kompromi dalam precision.

6. REFERENCES

- Akbarollah, M. F., Wiyanto, W., Ardiatma, D., & Zy, A. T. (2023). Penerapan Algoritma K-Nearest Neighbor Dalam Klasifikasi Penyakit Jantung. *Journal of Computer System and Informatics (JoSYC)*, 4(4), 850–860. <https://doi.org/10.47065/josyc.v4i4.4071>
- Alariyibi, A., El-Jarai, M., & Maatuk, A. (2023). Evaluating the Accuracy of Classification Algorithms for Detecting Heart Disease Risk. *Machine Learning and Applications: An International Journal*, 10(4), 01–12. <https://doi.org/10.5121/mlaj.2023.10401>
- Hakimah, M., & Muhimah, R. R. (2021). Klasifikasi Penderita Penyakit Jantung Menggunakan Metode Naive Bayes dengan Chi-Square untuk Pemilihan Atribut. *Seminar Nasional Teknik Elektro, Sistem Informasi Dan Teknik Informatika*, 1, 257–262.
- Kemkes, R. (2024). Berhaji dan Lansia. *Kementerian Kesehatan Republik Indonesia*. <https://ayosehat.kemkes.go.id/berhaji-dan-lansia>
- Kementerian Kesehatan Republik Indonesia. (2022). Penyakit Jantung Penyebab Utama Kematian, Kemenkes Perkuat Layanan Primer. *Public*, September 2022, 1–1. <https://sehatnegeriku.kemkes.go.id/baca/rilis-media/20220929/0541166/penyakit-jantung-penyebab-utama-kematian-kemenkes-perkuat-layanan-primer/>
- Laksono, A. D., Wulandari, R. D., Tumaji, T., Rukmini, R., Ipa, M., & Suharmiati, S. (2024). Traditional Health Services Utilization in Disadvantage Areas in Indonesia. *International Journal on Advanced Science, Engineering and Information Technology*, 14(1), 231–236. <https://doi.org/10.18517/ijaseit.14.1.18581>
- Makarim, F. R. (2021). Penyakit Jantung Koroner Rawan Dialami Lansia. *Halodoc*, 1. <https://www.halodoc.com/artikel/penyakit-jantung-koroner-rawan-dialami-lansia>
- Maskuri, M. N., Sukerti, K., & Herdian Bhakti, R. M. (2022). Penerapan Algoritma K-Nearest Neighbor (KNN) untuk Memprediksi Penyakit Stroke Stroke Disease Predict Using KNN Algorithm. *Jurnal Ilmiah Intech : Information Technology Journal of UMUS*, 4(1), 130–140.
- Melyani, M., Tambunan, L. N., & Baringbing, E. P. (2023). Hubungan Usia dengan Kejadian Penyakit Jantung Koroner pada Pasien Rawat Jalan di RSUD dr. Doris Sylvanus Provinsi Kalimantan Tengah. *Jurnal Surya Medika*, 9(1), 119–125. <https://doi.org/10.33084/jsm.v9i1.5158>
- Miller, C., Portlock, T., Nyaga, D. M., & O’Sullivan, J. M. (2024). A review of model evaluation metrics for

machine learning in genetics and genomics. *Frontiers in Bioinformatics*, 4(September), 1–13.
<https://doi.org/10.3389/fbinf.2024.1457619>

Nawawi, H. M., Purnama, J. J., & Hikmah, A. B. (2019). Komparasi Algoritma Neural Network Dan Naïve Bayes Untuk Memprediksi Penyakit Jantung. *Jurnal Pilar Nusa Mandiri*, 15(2), 189–194.
<https://doi.org/10.33480/pilar.v15i2.669>

Novitasari, F., Haerani, E., Nazir, A., Jasril, J., & Insani, F. (2023). Sistem Klasifikasi Penyakit Jantung Menggunakan Teknik Pendekatan SMOTE Pada Algoritma Modified K-Nearest Neighbor. *Building of Informatics, Technology and Science (BITS)*, 5(1), 274–284. <https://doi.org/10.47065/bits.v5i1.3610>

Nuryani, N., Purnama, B., Legowo, B., Utari, U., Riyatun, R., Suharno, S., Yudianto, M., & Lestari, W. (2023). Diseminasi Riset Kecerdasan Buatan Untuk Diagnosis Medis Berbasis Elektrokardiogram di Universitas Duta Bangsa. *SEMAR (Jurnal Ilmu Pengetahuan, Teknologi, Dan Seni Bagi Masyarakat)*, 12(2), 175.
<https://doi.org/10.20961/semar.v12i2.75521>

Sepharni, A., Hendrawan, I. E., & Rozikin, C. (2022). Klasifikasi Penyakit Jantung dengan Menggunakan Algoritma C4.5. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 7(2), 117.
<https://doi.org/10.30998/string.v7i2.12012>