29-11-2022-PrediksiPenyakitJantung-InComTech

by Agustiyar Agustiyar

Submission date: 29-Nov-2022 10:48AM (UTC+0700)
Submission ID: 1965861515
File name: 29-11-2022-PrediksiPenyakitJantung-InComTech_-_Copy.docx (706.21K)
Word count: 2350
Character count: 14325

Prediksi Penyakit Jantung Menggunakan *Attribute Weighting k*-Nearest Neighbor

Agustiyar[1*]

[1]*LLDIKTI Wilayah VI Semarang,*
*Email Penulis Koresponden: agustiyar001@gmail.com

Abstrak:
Penyakit kardiovaskular, populer dengan nama penyakit jantung menempati urutan tertinggi penyebab kematian di Indonesia dan tingkat global. Selain pola hidup sehat untuk mencegah penyakit tersebut, deteksi dini terhadap resiko penyakit jantung dapat dilakukan dengan data mining atau machine learning salah satunya *k*-NN. Algoritma *k*-NN merupakan metode data mining paling simpel dan kuat dalam konsistensi hasil klasifikasi, akan tetapi memiliki kekurangan yaitu memberikan bobot yang sama kepada semua atribut. Penelitian ini mengusulkan pembobotan pada atribut untuk mengatasi kelemahan tersebut. Prediksi penyakit jantung digunakan untuk menggambarkan kinerja metode usulan. Pada penelitian ini menggunakan dataset Heart Disease, sebuah dataset publik dari University of California Irvine. Dengan menggunakan nilai k 3, 5, 7, 9 diperoleh rata-rata kinerja metode usulan sebesar 79,87% lebih baik dibandingkan Chi-Square *k*-NN 79,08% dan *k*-NN klasik 65,89%. Penelitian ini menyimpulkan bahwa metode pembobotan atribut berhasil mengatasi kekurangan *k*-NN, jadi metode usulan cocok untuk prediksi penyakit jantung.

Kata Kunci:
Prediksi Penyakit Jantung;
k-Nearest Neighbor;
Pembobotan Atribut;
Weighted Euclidean Distance

1. PENDAHULUAN

Penyakit kardiovaskular, populer dengan nama penyakit jantung menjadi penyebab utama kematian pada tingkat global [1]. Pada tahun 2019 penyakit jantung menyebabkan kurang lebih 17,9 juta orang meninggal [2]. Di Indonesia penyakit kardiovaskular menempati posisi ke-dua setelah stroke dalam hal penyebab kematian [3]. Jadi, penyakit kardiovaskular menjadi penyebab kematian tertinggi baik di Indonesia maupun di tingkat global.

Penyakit kardiovaskular termasuk dalam kategori penyakit tidak menular yang dapat dihindari dengan gaya hidup sehat. Gaya hidup sehat tersebut dapat dilakukan dengan Gerakan Masyarakat Hidup Sehat (Germas) diantaranya melakukan pekerjaan fisik paling sedikit 30 menit sehari, mengonsumsi sayuran dan buah-

buahan, serta rutin melakukan pemeriksaan kesehatan [3]. Metode pencegahan yang lain adalah dengan memanfaatkan data mining atau machine learning [4] untuk deteksi dini terhadap resiko penyakit jantung.

Saat ini telah banyak penelitian tentang prediksi penyakit jantung menggunakan data mining atau machine learning, diantaranya penelitian Krishnaiah, Narsimha, dan Chandra, 2015 [4], di mana algoritma Fuzzy *k*-NN dan *k*-NN digunakan dalam memprediksi penyakit jantung. Penelitian R dan Thomas, 2017 [5], algoritma Naïve Bayes (NB), Decision Tree Algorithm, Neural Network (NN), dan *k*-NN digunakan dalam memprediksi penyakit jantung. Penelitian Mirza *et al.,* 2019 [6], algoritma SVM, Naïve Bayes, dan *k*-NN digunakan untuk memprediksi penyakit jantung.

Tahun 2016 Enriko, Suryanegara and Gunawan, 2016 [7] melakukan penelitian tentang penyakit jantung menggunakan algoritma *k*-NN dibandingkan dengan Naïve Bayes dan Decision tree. Hasil penelitian diperoleh kinerja algoritma *k*-NN mengungguli Decision Tree dan Naïve Bayes.

Pada tahun 2020, Singh dan Kumar, 2020 [8] mengadakan penelitian tentang prediksi penyakit jantung. Empat algoritma data mining diantaranya Random Forest, *k*-NN, Naïve Bayes, dan Decision Tree digunakan dalam penelitiannya. Hasilnya menempatkan metode *k*-NN menjadi metode dengan kinerja terbaik.

Algoritma *k*-NN merupakan algoritma klasifikasi yang populer, mengklasifikasi data tidak berlabel ke dalam data berlabel yang terdekat. Sejumlah *k* data berlabel yang dekat dengan data tidak berlabel dipilih, kemudian label yang sering muncul dari sejumlah *k* data berlabel tersebut dipilih menjadi label data yang semula tidak berlabel [9]. *k*-NN ialah algoritma klasifikasi yang simpel, bagus untuk klasifikasi data yang besar [10]. Menurut R dan Thomas [5] *k*-NN menjadi metode klasifikasi paling simpel dan kuat dalam konsistensi hasil klasifikasi.

Menurut Nayak et al. *k*-NN ialah algoritma klasifikasi yang simpel, namun hasil klasifikasinya sangat dipengaruhi oleh *irrelevant attributes* [10]. Menurut Liu, Zhu dan Qin [11] *k*-NN merupakan metode data mining paling simpel, akan namun mempunyai kekurangan, diantaranya ialah memberikan bobot yang sama kepada semua atribut.

Menurut Dialameh dan Jahromi, 2016 [12] pembobotan atribut dapat meningkatkan kinerja machine learning dengan mengatasi masalah yang diakibatkan irrelevant, redundant dan noisy atribut. Penelitian ini mengusulkan Attribute Weighting *k*-Nearest Neighbor, dengan menerapkan pembobotan pada atribut untuk mengatasi kelemahan *k*-NN yang memberikan bobot yang sama kepada semua atribut. Metode usulan akan dibandingkan dengan penelitian sebelumnya.

2. METODE

2.1 Penelitian Terkait

k-NN dikenal sebagai algoritma yang populer, simpel dan kuat dalam konsistensi hasil klasifikasi dan telah banyak digunakan dalam berbagai keperluan prediksi klasifikasi, diantaranya klasifikasi penyakit jantung. Penelitian [7] *k*-NN dengan pembobotan atribut Chi-Square digunakan untuk prediksi penyakit jantung. Penelitian [13] k-NN dikombinasikan dengan teknik Re-Sampling untuk prediksi penyakit jantung. Penelitian [14] *k*-NN dipadukan dengan data pre-processing

untuk prediksi penyakit jantung, hasilnya kinerja *k*-NN lebih unggul dari Random Forest, Naive Bayes (NB), dan Decision Tree (DT).

Algoritma *k*-NN merupakan algoritma klasifikasi paling sederhana, namun mempunyai kelemahan, di mana semua atribut dianggap memiliki bobot yang sama [11] sedangkan pada kenyataannya tidak semua atribut memiliki pengaruh yang sama terhadap kinerja algoritma [15]. Menurut [12] [16] pemberian bobot pada fitur atau atribut dapat meningkatkan kinerja algoritma.

Penelitian ini mengusulkan *Attribute Weighting* *k*-Nearest Neighbor, di mana pembobotan atribut diterapkan guna mengatasi kelemahan *k*-NN yang memberikan bobot yang sama kepada semua atribut. Metode usulan dibandingkan dengan penelitian sebelumnya.

2.2 Metode Pembobotan Atribut

Pada Gambar 2, Gambar 3 dicontohkan permasalahan klasifikasi *k*-NN pada data dengan dua atribut (a_1 dan a_2) dan tiga kelas/label, ketiga kelas tersebut adalah Merah (M), Biru (B), dan Hijau (H). Kita ambil dua data uji sebagai contoh, satu dari kelas M dan satu dari kelas B. Pada Gambar 2, klasifikasi *k*-NN dengan *k*=3, fungsi jarak Euclidean distance Fungsi

(2) tanpa pembobotan atribut, hasilnya dua data uji tersebut salah diklasifikasikan ke dalam kelas H. Hal ini terjadi karena atribut a_1 dan a_2 diperlakukan sama pentingnya oleh Euclidean distance.

Akan tetapi, jika Gambar 2 diperhatikan lebih dalam, pada kelas B sebaran data lebih banyak di a_1 sehingga dapat dikatakan a_1 berkontribusi lebih besar dibandingkan a_2 dalam menentukan anggota kelas B. Sementara pada kelas M, sebaran data lebih banyak di a_2 sehingga dapat dikatakan a_2 berkontribusi lebih besar dibandingkan a_1 dalam menentukan anggota kelas M. Sedangkan pada kelas G, a_1 dan a_2 tersebar secara merata dan dalam rentang yang sama sehingga dapat dikatakan a_1 dan a_2 memiliki kontribusi yang sama dalam menentukan anggota kelas G. Untuk itu pada Gambar 3, Euclidean distance ditambah bobot *W* sehingga disebut weighted Euclidean distance Fungsi

(3). Setiap atribut (a_1 dan a_2) pada kelas M, B, dan H diberikan bobot w_M, w_B, dan w_H dapat dilihat pada Fungsi (1).

$$\mathrm{W} = \begin{bmatrix} \mathrm{w_M} \\ \mathrm{w_B} \\ \mathrm{w_H} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 1 \end{bmatrix} \tag{1}$$

Dengan pemberian bobot *W* seperti itu kedua data uji dapat diklasifikasikan dengan benar oleh *k*-NN sebagaimana Gambar 3.

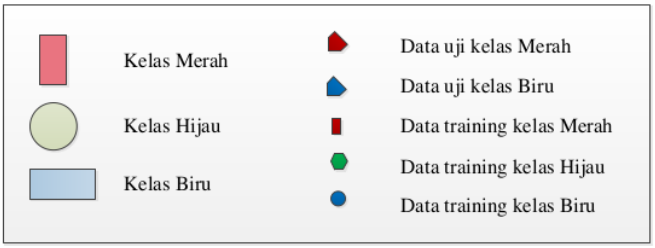

Gambar 1. Legenda Gambar 2, Gambar 3

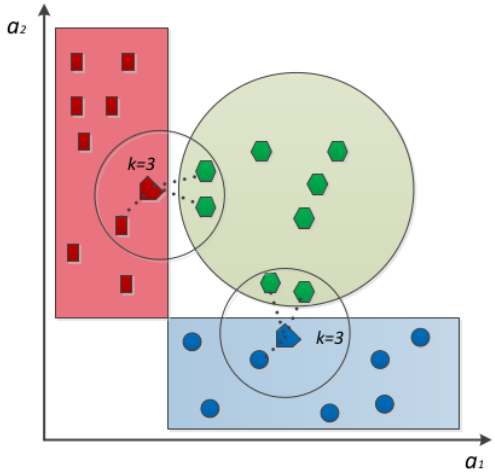

Gambar 2. *k*-NN Tanpa *Attribute Weighting*

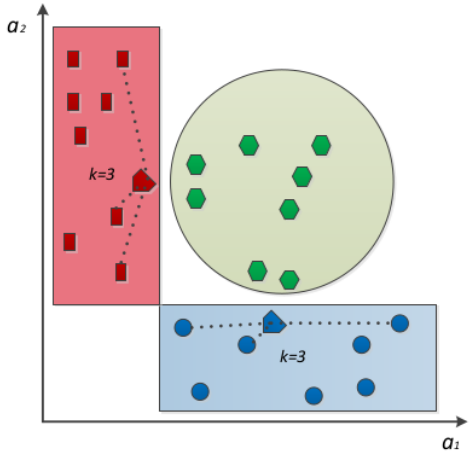

Gambar 3. *k*-NN dengan *Attribute Weighting*

2.3 Metode yang Diusulkan

Pada

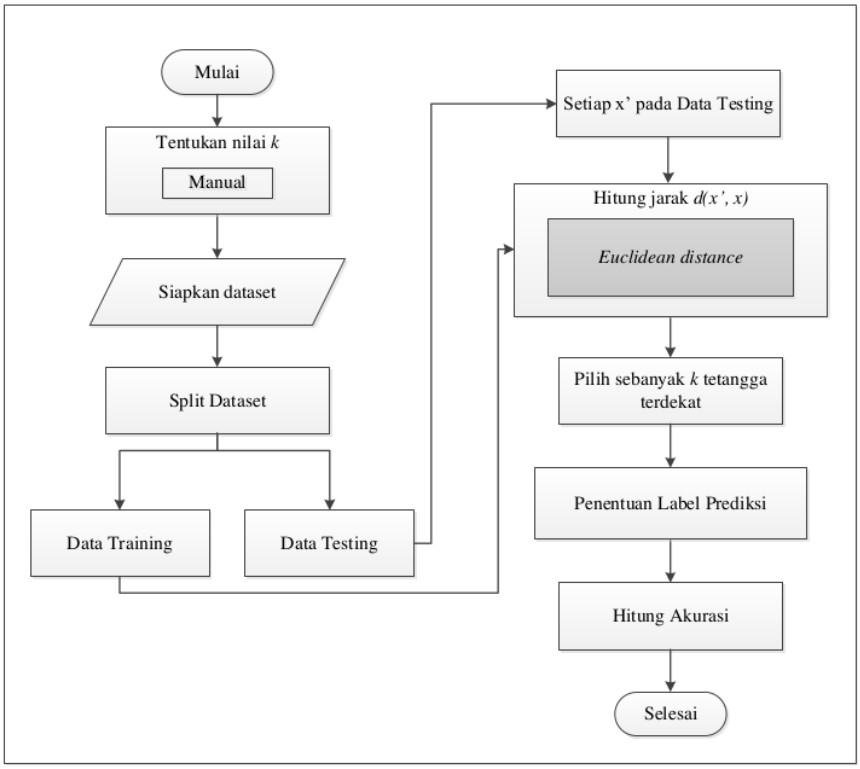

Gambar *4* ditunjukkan diagram aktifitas algoritma *k*-NN klasik, di mana *Euclidean distance* Fungsi (2) tanpa pembobotan digunakan sebagai fungsi jarak. Pada penelitian ini mengusulkan *Attribute Weighting k*-Nearest Neighbor (AWKNN), sebagaimana ditunjukkan pada Gambar 5. Perbedaan metode usulan dengan *k*-NN klasik terletak pada fungsi jarak yang digunakan, di mana metode usulan menggunakan *weighted Euclidean distance* sebagai fungsi jaraknya.

Pada metode usulan, w*eighted Euclidean distance* dipakai untuk menangani kelemahan *k*-NN yang memberikan bobot yang sama kepada semua atribut. Sebagaimana Gambar 5, nilai *k* ditentukan secara manual menggunakan nilai *k* ganjil [17] supaya tidak ambigu dalam penentuan label prediksi. Dataset dipecah menjadi dua, data latih dan data uji. Pada data latih, setiap atribut dihitung bobotnya dengan *coefficient of variation* Fungsi (5). Selanjutnya setiap data uji jaraknya dihitung terhadap data latih menggunakan *weighted Euclidean distance*. Kemudian mengambil sebanyak *k* tetangga untuk dijadikan kandidat hasil klasifikasi, penentuan label hasil klasifikasi menggunakan Fungsi

(8). Terakhir, mengukur kinerja metode usulan dengan menghitung akurasi.

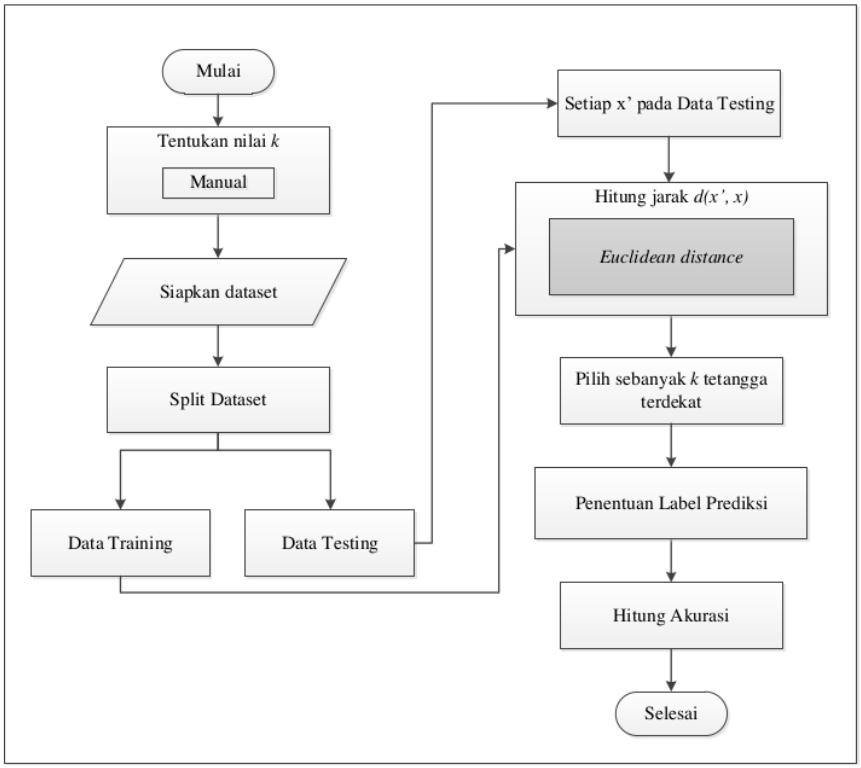

Gambar 4. Metode *k*-NN Klasik

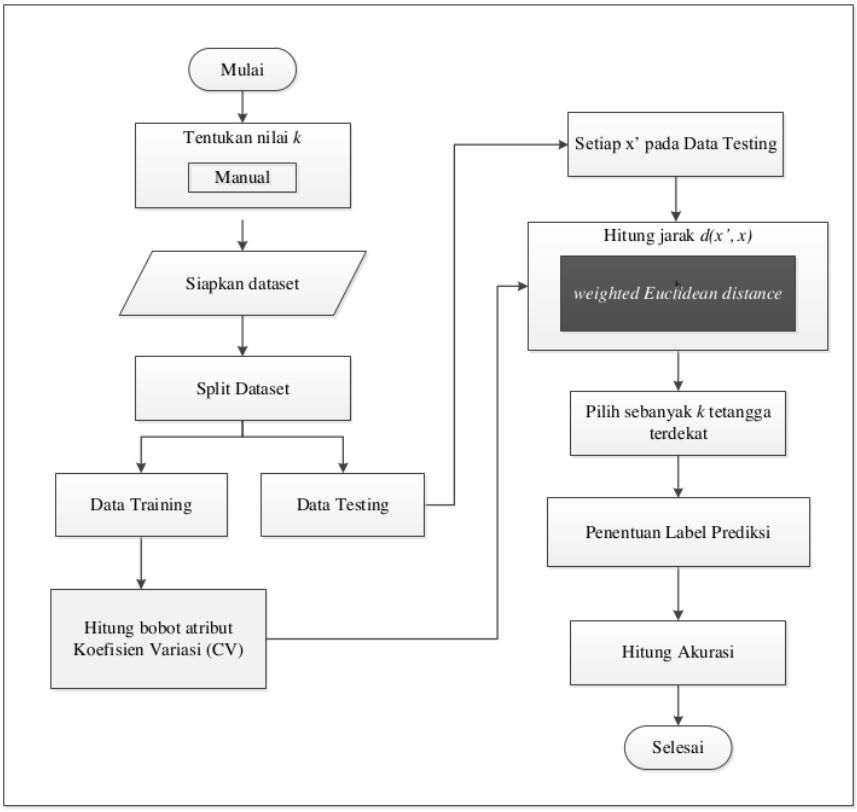

Gambar 5. Metode Usulan AWKNN

Euclidean distance dengan penambahan bobot (w) digunakan dalam menghitung jarak data latih terhadap data uji sebagaimana Fungsi (3) d: jarak, x': data uji, x: data latih, a: atribut, n: jumlah atribut, w: bobot dihitung dengan Fungsi (4) a: atribut, n: jumlah atribut, cv_a: koefisien variasi atribut ke-a. Koefisien variasi dihitung dengan Fungsi (5), δ_a: nilai standar deviasi atribut ke-a, μ_a: rata-rata atribut ke-a. Standar deviasi dihitung menggunakan Fungsi (6), a: atribut, m: jumlah data, y_{ia}: data ke-i atribut ke-a, μ_a: rata-rata atribut ke-a. Nilai rata-rata atribut dihitung dengan Fungsi (7), a: atribut, m: jumlah data, y_{ia}: data ke-i atribut ke-a. Pada metode usulan penentuan label hasil klasifikasi menggunakan Fungsi (8), l': label/kelas hasil klasifikasi, l: label/kelas, l_i: label/kelas ke-i dari k tetangga terdekat, k: jumlah tetangga terdekat.

$$d(x', x) = \sqrt{\sum_{a=1}^{n} (x'_a - x_a)^2} \tag{2}$$

$$d(x', x) = \sqrt{\sum_{a=1}^{n} w(x'_a - x_a)^2} \tag{3}$$

$$w_a = \frac{cv_a}{\sum_{a=1}^{n} cv_a} \tag{4}$$

$$cv_a = \frac{\delta_a}{\mu_a} \tag{5}$$

$$\delta_a = \sqrt{\frac{1}{n-1} \sum_{i=1}^{n} (y_{ia} - \mu_a)^2} \tag{6}$$

$$\mu_a = \frac{1}{n} \sum_{i=1}^{n} y_{ia} \tag{7}$$

$$l' = arg\ max_l \sum_{i=1}^{k} l = l_i \tag{8}$$

3. HASIL DAN PEMBAHASAN

Eksperimen dilakukan dengan laptop Intel Core i7, 8 Gigabyte Ram, Windows 10 Home 64-bit. Metode usulan dibangun dengan bahasa pemrograman Python.

Dataset Heart Disease (Hungarian) dari University of California Irvine digunakan dalam penelitian ini sebagaimana penelitian [7] [13] [14]. Dataset ini terdiri atas 303 data, 14 atribut, dan 2 label 0 (sehat) dan 1 (memiliki penyakit jantung). Pada dataset dilakukan *pre-processing*. Ringkasan Heart Disease dataset ditampilkan pada TABEL I.

Tabel I Ringkasan Heart Disease Dataset

No	Atribut	Keterangan
1	Age	Umur (th)
2	Sex	Kelamin (laki-laki atau perempuan)
3	Cp	Chest pain type/Jenis nyeri dada
4	Thestbps	Resting blood pressure (tekanan darah istirahat)
5	Cho	Serum cholesterol (kolesterol)
6	Restecg	Resting electrographic results (elektrografi istirahat)
7	Fbs	Fasting blood sugar (gula darah puasa)
8	Thalach	Detak jantung maksimal
9	Exang	Exercise induced angina
10	Oldpeak	ST depression induced by exercise relative to rest
11	Slope	Slope of the peak exercise ST segment
12	Ca	No. of major vessels colored
13	Thal	Jenis cacat
14	Label	0,1 (Healthy, Have Heart Disease)

Pada penelitian ini digunakan *state-of-the-art stratified 10-fold cross-validation* pada tahap pelatihan and pengujian, di mana dataset dibagi menjadi 10 bagian yang sama dan dilakukan proses *learning* sebanyak 10 kali. *10-fold cross-validation* digunakan karena cara ini menjadi cara validasi standar serta menjadi *state-of-the-art* dalam penelitian [18]. Pada Tabel II ditampilkan metode validasi *Stratified 10 Fold Cross Validation*. Dataset dibagi menjadi sepuluh bagian sama besar, pada validasi pertama, satu bagian yang berwarna hitam menjadi data uji sedangkan sembilan bagian yang tidak berwarna menjadi data latih. Ketika satu bagian menjadi data uji, sembilan bagian menjadi data latih, begitu seterusnya.

Tabel II Stratified 10 Fold Cross Validation

n-validasi	Partisi Dataset									
1	■									
2		■								
3			■							
4				■						
5					■					
6						■				
7							■			
8								■		
9									■	

Eksperimen pada algoritma *k*-NN klasik, dan metode usulan menggunakan nilai *k* (3,5,7,9) [19] kemudian hasilnya dibandingkan dengan penelitian [7]. Pada Tabel III ditampilkan hasil eksperimen metode usulan dan perbandingan dengan metode sebelumnya. Pada TABEL III ditampilkan akurasi algoritma yang diperbandingkan. Pada *k*-NN klasik akurasi tertinggi 66,77% diperoleh dengan *k=5,* sedangkan rata-ratanya sebesar 65,89%. Pada metode *Chi-Square*+*k*-NN [7] akurasi tertinggi 80,61% diperoleh dengan *k*=9, sedangkan rata-ratanya sebesar 79,08%. Pada metode usulan (AWKNN) akurasi tertinggi 81,32% diperoleh dengan *k*=3, sedangkan rata-ratanya sebesar 79,87%.

Tabel III Akurasi Algoritma yang Diperbandingkan

Metode/ Nilai *k*	***3***	***5***	***7***	***9***	***Rata-Rata***
k-NN klasik	65,14%	66,77%	65,35%	66,32%	65,89%
Chi-Square+*k*-NN [7]	78,23%	79,25%	78,23%	80,61%	79,08%
Metode Usulan (AWKNN)	81,32%	80,28%	78,26%	79,62%	**79,87%**

4. KESIMPULAN

Attribute Weighting *k*-Nearest Neighbor (AWKNN) merupakan pengembangan *k*-NN di mana Euclidean Distance diubah menjadi Weighted Euclidean Distance. Dengan Weighted Euclidean Distance, bobot setiap atribut diperhitungkan dalam mengukur kedekatan antar data. Hasil uji coba AWKNN pada prediksi penyakit jantung dengan dataset publik Heart Disease dataset (Hungarian) diperoleh hasil kinerja AWKNN lebih unggul dibanding algoritma *k*-NN klasik. Dengan *attribute weighting* berhasil meningkatkan kinerja machine learning sesuai penelitian [12]. Jadi metode yang diusulkan mampu mengatasi kekurangan algoritma *k*-NN.

Pada penelitian ini untuk meningkatkan kinerja *k*-NN dilakukan pembobotan atribut. Saran untuk penelitian selanjutnya dapat dicoba pembobotan pada neighbors untuk meningkatkan kinerja *k*-NN.

REFERENSI

[1] World Health Organization, “The top 10 causes of death,” 2020.

[2] World Health Organization, “Cardiovascular diseases (CVDs),” *WHO reports*, no. June, CRC Press, pp. 6–7, 11-Jun-2021.

[3] Kemenkes, "Penyakit jantung penyebab kematian terbanyak ke-2 di indonesia," *Kementrian Kesehat. Republik Indones.*, no. September, pp. 1–2, 2019.

[4] V. Krishnaiah, G. Narsimha, and N. S. Chandra, "Heart Disease Prediction System Using Data Mining Technique by Fuzzy K-NN Approach," vol. 1, no. V, pp. 371–384, 2015.

[5] T. P. R and J. Thomas, "Human Heart Disease Prediction System using Data Mining Techniques," *Proc. IEEE Int. Conf. Circuit, Power Comput. Technol. ICCPCT 2017*, 2017.

[6] I. Mirza, A. Mahapatra, D. Rego, and K. Mascarenhas, "Human Heart Disease Prediction Using Data Mining Techniques," in *2019 International Conference on Advances in Computing, Communication and Control (ICAC3)*, 2019, pp. 1–5.

[7] I. K. A. Enriko, M. Suryanegara, and D. Gunawan, "Heart disease prediction system using k-Nearest neighbor algorithm with simplified patient's health parameters," *J. Telecommun. Electron. Comput. Eng.*, vol. 8, no. 12, pp. 59–65, 2016.

[8] A. Singh and R. Kumar, "Heart Disease Prediction using Machine Learning Algorithms," in *2020 International Conference for Emerging Technology (INCET)*, 2020, pp. 1–7.

[9] C. Raju, E. Philipsy, S. Chacko, L. P. Suresh, and D. R. S, "A Survey on Predicting Heart Disease using Data Mining Techniques," no. March, pp. 2–3, 2018.

[10] S. Nayak, M. K. Gourisaria, M. Pandey, and S. S. Rautaray, "Prediction of heart disease by mining frequent items and classification techniques," *2019 Int. Conf. Intell. Comput. Control Syst. ICCS 2019*, no. Iciccs, pp. 607–611, 2019.

[11] S. Liu, P. Zhu, and S. Qin, "An improved weighted knn algorithm for imbalanced data classification," *2018 IEEE 4th Int. Conf. Comput. Commun. ICCC 2018*, pp. 1814–1819, 2018.

[12] M. Dialameh and M. Z. Jahromi, "Proposing a General Feature Weighting Function," *Expert Syst. Appl.*, 2016.

[13] N. Khateeb and M. Usman, "Efficient heart disease prediction system using K-nearest neighbor classification technique," *ACM Int. Conf. Proceeding Ser.*, pp. 21–26, 2017.

[14] D. Shah, S. Patel, and S. K. Bharti, "Heart Disease Prediction using

Machine Learning Techniques," *SN Comput. Sci.*, vol. 1, no. 6, pp. 1–6, 2020.

[15] K. Siminski, "Fuzzy weighted C-ordered means clustering algorithm," *Fuzzy Sets Syst.*, vol. 1, pp. 1–33, 2017.

[16] J. Wu, S. Pan, X. Zhu, Z. Cai, P. Zhang, and C. Zhang, "Self-adaptive attribute weighting for Naive Bayes classification," *Expert Syst. Appl.*, vol. 42, no. 3, pp. 1487–1502, 2015.

[17] V. Kotu and B. Deshpande, *Predictive Analytics using Rapidminer*. Elsevier, 2015.

[18] I. Witten, E. Frank, and M. Hall, *Data Mining Practical Machine Learning Tools and Techniques Third Edition*, vol. 277. Elsevier Inc., 2011.

[19] A. B. Hassanat, M. A. Abbadi, and A. A. Alhasanat, "Solving the Problem of the K Parameter in the KNN Classifier Using an Ensemble Learning Approach," *Int. J. Comput. Sci. Inf. Secur.*, vol. 12, no. 8, pp. 33–39, 2014.

29-11-2022-PrediksiPenyakitJantung-InComTech

ORIGINALITY REPORT

5%	2%	5%	%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	Agustiyar Agustiyar, Romi Satria Wahono, Catur Supriyanto. "Metode Pembobotan Jarak dengan Koefisien Variasi untuk Mengatasi Kelemahan Euclidean Distance pada Algoritma k-Nearest Neighbor", Jurnal Ilmiah SINUS, 2022 Publication	3%
2	Nida Khateeb, Muhammad Usman. "Efficient Heart Disease Prediction System using K-Nearest Neighbor Classification Technique", Proceedings of the International Conference on Big Data and Internet of Thing - BDIOT2017, 2017 Publication	1%
3	Moh. Zainuddin. "METODE KLASIFIKASI BERBASIS PARTICLE SWARM OPTIMIZATION (PSO) UNTUK PREDIKSI KELULUSAN TEPAT WAKTU MAHASISWA", Jurnal Ilmiah Teknologi Informasi Asia, 2018 Publication	<1%
4	ebin.pub Internet Source	<1%

Exclude quotes	Off	Exclude matches	Off
Exclude bibliography	On		