

Komparasi Metrik Euclidean, Metrik Manhattan, dan Metrik Chebyshev pada *K-Nearest Neighbor* dalam Klasifikasi Jenis Kurma

¹**Moch. Anjas Aprihartha, ²Ratono, ³Dian Puput Utami**

^{1,2,3}Program Studi PJJ Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro
e-mail: moch.anjas.aprihartha@dsn.dinus.ac.id

Abstract

Sorting and inspecting dates are a challenging and crucial process in the agricultural and food industries, requiring skilled and experienced workers. However, this challenge can be overcome by adapting machine learning algorithms capable of automatically sorting dates based on their characteristics. As a nonparametric machine learning algorithm, k-nearest neighbor (KNN) principally operates on the premise that samples that are close together in feature space tend to belong to the same category. The key to effective KNN classification lies in selecting the k value and determining the appropriate metric. This study will use the KNN method with different distance metrics such as the Euclidean metric, the Manhattan metric, and the Chebyshev metric for k = 3, 5, and 7. The aim of this research is to study the design and manufacture of tools that involve intelligent systems to differentiate date types. This study found that the Euclidean distance metric with k = 7 produced the highest accuracy compared to other KNN models, namely 87%. This model is quite good at distinguishing date types based on their morphological characteristics, color, and fruit shape. This research is expected to contribute to the development of intelligent systems for assessing and inspecting date fruit types.

Keywords: Dates, Chebyshev, Euclidean, KNN, Manhattan

Abstrak

Pemilahan dan pemeriksaan buah kurma merupakan proses yang menantang dan krusial dalam sektor pertanian maupun industri pangan karena membutuhkan tenaga kerja yang terampil dan berpengalaman. Namun, tantangan ini dapat diatasi dengan mengadaptasi algoritma *machine learning* yang mampu memilah secara otomatis buah kurma berdasarkan karakteristiknya. Sebagai algoritma *machine learning* nonparametrik, *k-nearest neighbors* (KNN) pada prinsipnya beroperasi berdasarkan premis bahwa sampel yang berdekatan dalam ruang fitur cenderung termasuk dalam kategori yang sama. Kunci penting untuk klasifikasi KNN yang efektif terletak pada pemilihan nilai k dan menentukan metrik yang tepat. Penelitian ini akan menggunakan metode KNN dengan metrik jarak berbeda seperti metrik Euclidean, metrik Manhattan, dan metrik Chebyshev untuk setiap $k = 3, 5$, dan 7 . Tujuan penelitian ini dapat menjadi bahan kajian dalam perancangan dan pembuatan alat dengan melibatkan sistem cerdas untuk membedakan jenis buah kurma. Penelitian ini menghasilkan temuan metrik jarak Euclidean dengan $k = 7$ menghasilkan akurasi tertinggi diantara model KNN lainnya, yaitu akurasi 87%. Model ini cukup baik dalam membedakan jenis kurma berdasarkan karakteristik morfologi, warna, dan bentuk buahnya. Penelitian ini diharapkan dapat memberikan kontribusi untuk mengembangkan sistem cerdas untuk menilai dan memeriksa jenis buah kurma.

Kata kunci: Chebyshev, Euclidean, KNN, Kurma, Manhattan

Diterima : 12 August 2025
Disetujui : 09 Desember 2025
Dipublikasi: 31 Desember 2025

Pendahuluan

Pemilahan dan pemeriksaan buah kurma merupakan proses yang menantang dan krusial dalam sektor pertanian maupun industri pangan karena membutuhkan tenaga kerja yang terampil dan berpengalaman. Selain itu, pergantian tenaga kerja dalam industri pengolahan kurma

meningkat secara berkala (Maitlo *et al.*, 2024). Oleh karena itu, karena kurangnya tenaga kerja terlatih, kualitas buah kurma sering kali terganggu. Hal ini menyebabkan pemborosan buah dan ketidakstabilan harga buah. Saat ini, algoritma pembelajaran telah menarik perhatian komunitas peneliti dalam memecahkan masalah di sektor pertanian.

Sebagai salah satu algoritma *machine learning* nonparametrik, *k-nearest neighbors* (KNN) telah banyak diaplikasikan untuk klasifikasi dan regresi di berbagai bidang. Dalam beberapa tahun terakhir, penelitian tentang algoritma KNN telah diterapkan secara luas (Xu, 2025). Penelitian oleh Aprihartha *et al.* (2024) yang membandingkan metrik Euclidean dan metrik Manhattan pada KNN dalam mengklasifikasikan kismis. Penelitian oleh Liang *et al.* (2023) yang menggunakan metode KNN untuk memprediksi beban pendinginan dan pemanasan bangunan secara detail selama setahun penuh pada tahap pra-desain.

Dibandingkan dengan algoritma lain yang sudah ada, pengklasifikasi KNN ini memiliki akurasi klasifikasi yang lebih tinggi (Vinoth & Sasireka, 2023). Menurut Xu & Fan (2025), kunci untuk klasifikasi KNN yang efektif terletak pada pemilihan nilai *k* dan menentukan metrik yang tepat dalam membandingkan sampel yang dikumpulkan dengan sampel baru dari kategori yang tidak diketahui. Bentuk umum ukuran kesamaan meliputi berbagai metrik jarak seperti jarak Euclidean, Manhattan, dan Chebyshev. Setelah nilai kesamaan dihitung, tetangga terdekat dari sampel baru diidentifikasi, dan sampel baru diberi label kategori yang paling sering muncul di antara tetangga terdekatnya.

Teknik KNN telah diterapkan secara produktif dalam proses pemilahan buah kurma berdasarkan karakteristiknya seperti bentuk, warna, dan ukuran buahnya. Penelitian oleh Al Maki *et al.* (2023) yang menggunakan algoritma KNN dengan metrik Euclidean dalam mengklasifikasi buah kurma. Hasil penelitiannya diperoleh akurasi dari algoritma KNN menggunakan *k* = 3, 5, dan 7 masing-masing mencapai 81,85%, 84,62%, dan 85,38%. Meskipun memiliki kinerja yang cukup baik dalam mengklasifikasikan buah kurma, hasil ini mengindikasikan bahwa model KNN dapat mengetahui pola-pola dalam data. Metode KNN masih dapat ditingkatkan lebih lanjut dengan menetapkan nilai *k* terbaik dan memilih metrik yang tepat agar akurasi model dapat ditingkatkan.

Oleh karena itu, masalah klasifikasi dan penyortiran buah kurma telah menjadi hal yang umum dalam sektor pertanian dan industri pangan. Berdasarkan masalah tersebut, pada penelitian ini akan dilakukan identifikasi jenis buah kurma berdasarkan ciri-ciri morfologi buah kurma. Penelitian ini bertujuan sebagai bahan kajian dalam perancangan dan pembuatan alat dengan melibatkan sistem cerdas untuk membedakan jenis buah kurma. Teknik yang diterapkan adalah KNN dengan pendekatan metrik jarak berbeda seperti metrik Euclidean, metrik Manhattan, dan metrik Chebyshev. Penelitian ini diharapkan dapat memberikan kontribusi untuk mengembangkan sistem cerdas untuk menilai dan memeriksa jenis buah kurma.

Metode Penelitian

2.1 Jenis Data dan Variabel Penelitian

Data yang menjadi dasar dalam penelitian ini merupakan data sekunder yang diperoleh dari *platform* yang menyediakan kumpulan dataset, Kaggle. Data asli merupakan data citra yang telah diekstraksi menjadi data numerik. Dataset terdiri dari 897 amatan dengan 34 atribut yang menyatakan fitur morfologi, bentuk, dan warna dari ketujuh jenis buah kurma. Tujuh jenis buah kurma diantaraya Barhee, Deglet Nour, Sukkary, Rotab Mozafati, Ruthana, Safawi, dan Sagai.

Tabel 1. Atribut Data

Atribut Utama	Sub Atribut
Fitur Morfologi	<i>Area, Perimeter, Major Axis, Minor Axis, Eccentricity, Equivalent Diameter, Solidity, Convex Area, Extent, Aspect Ratio, Roundness, Compactness</i>
Fitur Bentuk	<i>Shapefactor 1, Shapefactor 2, Shapefactor 3, Shapefactor 4</i>
Fitur Warna	<i>Mean RR, Mean RG, Mean RB, Std.dev RR, Std.dev RG, Std.dev RB, Skew RR, Skew RG, Skew RB, Kurtosis RR, Kurtosis RG, Kurtosis RB, Entropy RR, Entropy RG, Entropy RB, All daub4 RR, All daub4 RG, All daub4 RB</i>

2.2 K-Nearest Neighbor (KNN)

Pada prinsipnya klasifikasi KNN beroperasi berdasarkan premis bahwa sampel yang berdekatan dalam ruang fitur cenderung termasuk dalam kategori yang sama (Rastin *et al.*, 2021). KNN memprediksi label kategori sampel baru dengan memanfaatkan kesamaan antara sampel baru dan sampel yang diketahui (Xu & Fan, 2025). Kunci klasifikasi KNN yang efektif terletak pada pemilihan atau perancangan ukuran kesamaan yang tepat untuk membandingkan sampel yang dikumpulkan dengan sampel baru dari kategori yang tidak diketahui. Selain itu kinerja klasifikasi KNN bergantung juga pada nilai k , yang menentukan jumlah tetangga terdekat yang dipertimbangkan untuk sampel baru. Ukuran kesamaan umum mencakup berbagai metrik jarak seperti jarak Euclidean, jarak Manhattan, dan jarak Chebyshev yang masing-masing dinyatakan dalam persamaan (1), (2), (3).

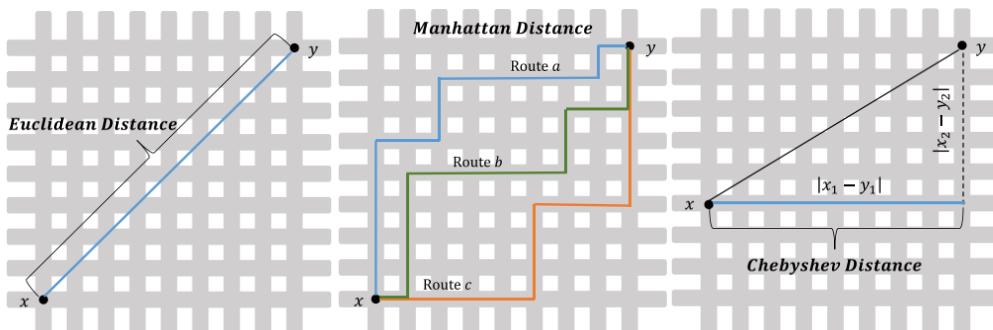
$$\text{Jarak}_{\text{Euclidean}} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

$$\text{Jarak}_{\text{Manhattan}} = \sum_{i=1}^n |x_i - y_i| \quad (2)$$

$$\text{Jarak}_{\text{Chebyshev}} = \max_{i=1,2,\dots,n} |x_i - y_i| \quad (3)$$

Jarak Euclidean adalah jarak garis lurus antara dua titik seperti yang ditunjukkan pada Gambar 1 dan dapat mengukur data struktur hipersfer melingkar dalam ruang berdimensi tinggi (Liang *et al.*, 2023). Jarak Manhattan adalah jumlah panjang yang diproyeksikan ke sumbu oleh jalur terpendek yang harus diikuti seseorang yang bergerak selangkah demi selangkah ke titik lain dalam sistem koordinat. Rute dalam jarak Manhattan ditunjukkan pada Gambar 1, di mana titik x hanya dapat dipindahkan secara tegak lurus ke titik y, bukan secara diagonal, sementara panjang

route a, b, dan c setara. Jarak Chebyshev adalah nilai absolut maksimum dari selisih numerik antara dimensi yang bersesuaian dari dua titik vektor, yaitu, jarak maksimum sepanjang sumbu.



Gambar 1. Jenis-jenis Metrik Jarak

Algoritma KNN secara umum diuraikan pada langkah-langkah sebagai berikut:

1. Menghitung menggunakan metrik jarak antara objek baru dengan setiap objek pada yang terdapat pada dataset latih.
2. Menentukan k objek terdekat dari dataset latih berdasarkan hasil perhitungan jarak.
3. Menentukan kategori objek baru dengan kategori yang sering muncul diantara k objek terdekat.
4. Jumlah k tetangga terdekat dapat disusun menjadi suatu kelompok berdasarkan kesamaan karakteristik.
5. Proses penentuan kategori diterapkan dengan menggunakan pemungutan suara terbanyak (*majority voting*).

2.4 Matriks Performa Model Klasifikasi

Dalam konteks klasifikasi, evaluasi performa model didasarkan pada total penilaian amatan data yang terkласifikasi benar dan terkласifikasi salah (Aprihartha *et al.*, 2024). Untuk mengidentifikasi hal tersebut maka hasil klasifikasi disusun dalam bentuk *confusion matrix*. Pada *confusion matrix* terdiri dari bagian baris yang mencerminkan kelas-kelas aktual sedangkan bagian kolom yang mencerminkan kelas-kelas prediksi.

Tabel 2. *Confusion Matrix*

		Prediksi			
		Kelas 1	Kelas 2	...	Kelas p
Aktual	Kelas 1	T_1	F_{12}	...	F_{1p}
	Kelas 2	F_{21}	T_2	...	F_{2p}
			:		
	Kelas p	F_{p1}	F_{p2}	...	T_p

Kinerja model klasifikasi dapat diukur dengan melihat tingkat keberhasilan atau akurasi berdasarkan kemampuan model mampu mengklasifikasikan data ke dalam kelas yang sesuai. Akurasi adalah salah satu indikator yang paling banyak digunakan dalam klasifikasi kelas dan

dalam perhitungannya mengambil data dari *confusion matrix*. Akurasi dinyatakan sebagai persentase dari total keseluruhan amatan yang terprediksi atau terkласifikasi secara tepat.

$$Akurasi = \frac{\sum T_i}{\sum T_i + \sum F_{ij}} \times 100\%; i, j = 1, 2, \dots, p \quad (3)$$

dengan T_i merupakan amatan yang terkласifikasi benar dan F_{ij} merupakan amatan yang terkласifikasi salah.

Hasil dan Pembahasan

Hasil Uji K-Nearest Neighbor (KNN)

Sebelum proses pembuatan model klasifikasi dimulai, dataset akan diolah dengan transformasi *Z-Score Normalization* untuk menormalkan skala data pada setiap variabel independen. Proses ini dilakukan dengan menggunakan persamaan sebagai berikut.

$$Z = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad (4)$$

dengan x_{ij} merupakan observasi ke- i pada variabel ke- j , \bar{x}_j merupakan rata-rata pada variabel ke- j , dan σ_j merupakan deviasi standar pada variabel ke- j . Hasil transformasi disajikan dalam Tabel 2.

Tabel 2. Hasil Transformasi Data

No.	Area	Perimeter	Major Axis	...	Kelas
1	1,154	0,783	0,604	...	Berhee
2	0,371	0,067	-0,187	...	Berhee
3	2,131	1,438	1,318	...	Berhee
:	:	:	:	:	:
898	0,424	0,564	0,506	...	Sagai

Setelah proses transformasi, kemudian dataset dibagi menjadi dua bagian, yaitu dataset latih dan dataset uji. Pada proses ini ditetapkan rasio 7:3 dengan ketentuan 70% dataset sebagai dataset latih dan sisanya 30% sebagai dataset uji. Dalam membangun dataset latih digunakan teknik *simple random sampling*. Teknik ini bekerja dengan mengambil amatan secara acak sehingga setiap amatan memiliki kesempatan yang sama untuk masuk kedalam dataset latih sedangkan sisanya yang tidak terpilih masuk kedalam dataset uji. Dataset semula terdiri 898 amatan yang dialokasikan menjadi dataset latih sebanyak 698 amatan dan sisanya 270 amatan sebagai dataset uji. Dataset latih dan dataset uji ditampilkan pada Tabel 3 dan Tabel 4.

Tabel 3. Dataset Latih

No.	Area	Perimeter	Major Axis	...	Kelas
1	1,154	0,783	0,604	...	Berhee
107	0,347	0,043	0,065	...	Safawi
234	2,741	1,764	2,457	...	Safawi
:	:	:	:	:	:
698	0,424	0,564	0,506	...	Sogay

Tabel 4. Dataset Uji

No.	Area	Perimeter	Major Axis	...	Kelas

111	2,124	3,311	2,122	...	Sukkary
678	0,211	2,011	3,211	...	Safawi
431	1,213	1,112	0,211	...	Ruthana
⋮	⋮	⋮	⋮	⋮	⋮
270	0,424	0,564	0,506	...	Sagai

Proses pembentukan model klasifikasi dilakukan dengan melatih model KNN melalui pendekatan metrik Euclidean, metrik Manhattan, dan metrik Chebyshev. Pada tiap-tiap metrik, dilakukan pengujian dengan indikator $k = 3, 7, 5$ untuk menentukan jarak terdekat antara data yang diuji dengan tetangga terdekatnya. Kemudian hasil uji disajikan dalam bentuk *confusion matrix* seperti pada Tabel 5.

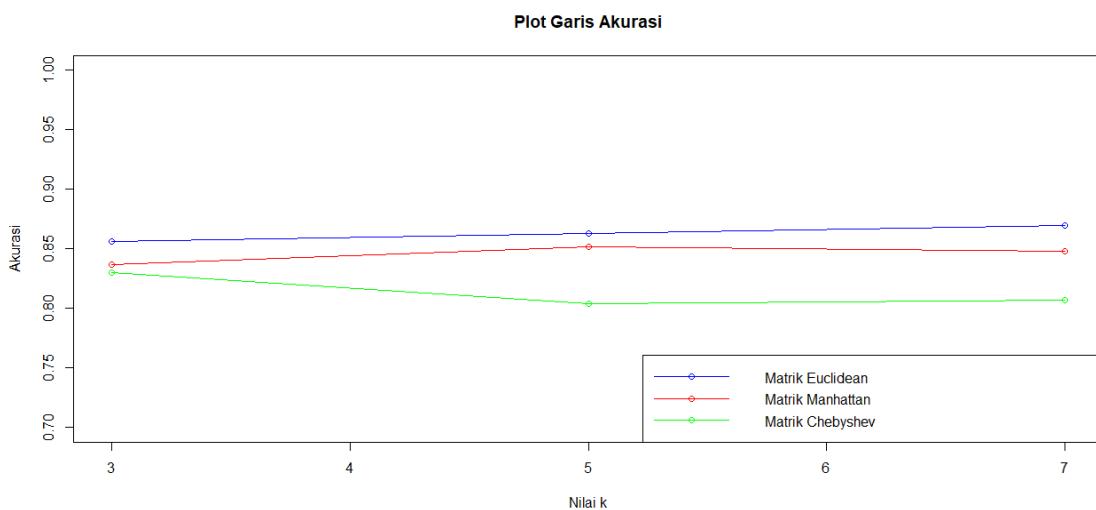
Tabel 5. *Confusion Matrix* Dataset Uji

Aktual	Prediksi							
		Barhee	Deglet Nour	Sukkary	Rotab Mozafati	Ruthana	Safawi	Sagai
Barhee	19	0	0	1	0	0	0	0
Deglet Nour	0	19	2	0	0	0	0	8
Sukkary	0	8	60	0	0	0	0	1
Rotab Mozafati	2	0	0	15	0	0	0	0
Ruthana	1	0	0	2	43	0	0	7
Safawi	0	0	0	0	0	56	0	0
Sagai	0	5	0	0	1	1	0	19

Pada Tabel 5 merupakan salah satu hasil pengujian dari data uji terhadap model KNN metrik Euclidean pada indikator $k = 3$. Kemampuan model dalam klasifikasi diukur melalui perhitungan akurasi sebagai berikut:

$$\text{Akurasi} = \frac{19 + 19 + 60 + 15 + 43 + 56 + 19}{270} = 0,8555$$

Performa model menghasilkan akurasi sebesar 0,8555 yang menunjukkan bahwa model berhasil mengklasifikasikan data dengan benar sebesar 85,55% dari total amatan pada dataset uji sedangkan sisanya 14,45% gagal terkласifikasi dengan benar. Setiap akurasi model KNN dengan metrik Euclidean, metrik Manhattan, dan metrik Chebyshev dengan $k = 3, 5, 7$ ditunjukkan dalam plot garis akurasi seperti pada Gambar 2.



Gambar 2. Plot Akurasi Model Setiap Metrik Jarak

Pada Gambar 2 diperlihatkan, akurasi dari KNN metrik Euclidean yang ditandai dengan garis warna biru. KNN metrik Euclidean memiliki akurasi paling tinggi dan stabil. Terjadi peningkatkan akurasi dari $k = 3, 5, 7$ yang masing-masing sebesar 0,856; 0,863; 0,870. Akurasi dari KNN metrik Manhattan ditunjukkan dengan garis warna merah. KNN metrik Manhattan memiliki akurasi dibawah KNN metrik Euclidean. Akurasi untuk $k = 3, 5, 7$ yang masing-masing sebesar 0,837; 0,852; 0,848. Sementara itu, akurasi KNN metrik Chebyshev ditandai dengan warna hijau. Performa model KNN metrik ini menunjukkan akurasi paling rendah diantara KNN metrik Euclidean dan Manhattan. Akurasi dari KNN metrik Chebyshev untuk $k = 3, 5, 7$ berturut-turut sebesar 0,83; 0,804; 0,807.

KNN metrik Euclidean merupakan model yang optimal dalam mengklasifikasi jenis buah kurma dibandingkan KNN metrik Manhattan maupun metrik Chebyshev. Pada kasus ini ditetapkan KNN metrik Euclidean dengan $k = 7$ sebagai model terbaik karena memiliki akurasi paling tinggi dibandingkan model lainnya. Nilai k yang semakin tinggi tidak menunjukkan peningkatkan performa model yang lebih baik. Ini dibuktikan ketika akurasi akurasi juga terjadi KNN metrik Manhattan dari $k = 5$ ke $k = 7$. Selain itu, KNN metrik Chebyshev menunjukkan penurunan seiring bertambahnya nilai k .

Pembahasan

Pemilihan metrik jarak dan *hyperparameter k* berpengaruh besar terhadap kinerja model kerena kedua faktor tersebut yang menentukan data baru diklasifikasikan berdasarkan kedekatan dengan dataset latih. Metrik jarak seperti Euclidean, Manhattan, dan Chebyshev dapat mempengaruhi model dalam mengukur kesamaan antar data, sehingga akan berakibat pada hasil klasifikasi. Sedangkan nilai k menentukan jumlah tetangga terdekat yang menjadi pertimbangan model dalam mengambil keputusan.

Berdasarkan hasil uji yang diperoleh metrik jarak Euclidean memberikan akurasi lebih baik dibandingkan dengan metrik jarak Manhattan dan Chebyshev. Sementara itu, nilai $k = 7$ ditetapkan dalam pengambilan keputusan terbaik karena berdasarkan hasil uji model KNN metrik Euclidean, diperoleh akurasi tertinggi diantara model KNN lainnya, yaitu sebesar 0,870 (87%). Hasil ini sejalan pada penelitian dari (Ujianto *et al.*, 2025) yang menerapakan algoritma KNN dalam indentifikasi citra medis. Pada eksperimen tersebut metrik jarak Euclidean menghasilkan akurasi sempurna sebesar 90% dibandingkan metrik jarak Minkowski dan Cosine. Selain itu, pada proses eksekusi program, model KNN metrik Euclidean memberikan waktu lebih singkat dibandingkan metrik Manhattan dan Chebyshev. Hasil ini senada dalam penelitian oleh Pariyasto (2025), menjelaskan bahwa metrik jarak Euclidean bekerja lebih cepat dibandingkan dengan metrik jarak Manhattan. Menurut Schmitz (2024), keuntungan dari pendekatan KNN adalah kemudahan implementasinya dan biaya komputasi yang rendah. Hal ini membuat metode ini dapat terapkan secara efisien ketika bekerja dengan jumlah data yang besar dan dengan sistem kapasitas pemrosesan yang sangat terbatas.

Kesimpulan

Berdasarkan hasil dan pembahasan maka dapat dirumuskan kesimpulan. Pemilihan metrik jarak dan *hyperparameter k* menjadi faktor dalam menentukan capaian kinerja model klasifikasi. Capaian kinerja model KNN pada masing-masing metrik jarak memberikan akurasi berbeda untuk $k = 3, 5, 7$. Pada metrik jarak Euclidean menghasilkan akurasi yang masing-masing sebesar 0,856; 0,863; 0,870. Kemudian, metrik jarak Manhattan memberikan akurasi masing-masing sebesar 0,837; 0,852; 0,848. Sementara itu, metrik jarak Chebyshev menghasilkan akurasi sebesar 0,83; 0,804; 0,807. Hasil uji diperoleh bahwa metrik jarak Euclidean memberikan akurasi lebih baik dibandingkan dengan metrik jarak Manhattan dan Chebyshev. Jumlah tetangga terdekat dalam pengambilan keputusan terbaik pada model KNN Euclidean adalah $k = 7$, yang menghasilkan akurasi model sebesar 0,870 atau 87%. Dengan demikian, model ini cukup baik dalam membedakan jenis kurma berdasarkan karakteristik morfologi, warna, dan bentuk buahnya. Meski begitu, terdapat 13% data yang terklasifikasi salah, yang disebabkan kemungkinan ada faktor seperti parameter k yang belum optimal atau pemilihan model yang kurang tepat. Oleh karena itu saran yang dapat dilakukan untuk penelitian selanjutnya dengan menguji beberapa algoritma berbeda seperti decision tree, Naive Bayes, random forest, dll. atau eksplorasi metrik jarak lainnya seperti Minkowski, Cosine, dll. atau melakukan uji rentang k yang lebih luas untuk mendapatkan k optimal.

Daftar Pustaka

- Al Maki, W. F., Mauladan, K., & Muktyas, I. B. (2023). Date Fruit Classification Using K-Nearest Neighbor with Principal Component Analysis and Binary Particle Swarm Optimization. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(6), 1456-1463.
- Aprihartha, M. A., Alam, T. N., & Husniyadi, M. (2024). Perbandingan Metrik Euclidean dan Metrik Manhattan untuk K-Nearest Neighbors dalam Klasifikasi Kismis. *Jurnal Ilmu Komputer dan Informatika*, 4(1), 21-30.
- Aprihartha, M. A., Prasetya, J., & Fallo, S. I. (2024). Implementasi CART-Real Adaboost dalam Memprediksi Minat Pelanggan Membeli Sepatu. *Jurnal EurekaMatika*, 12(1), 35-46.
- Liang, Y., Pan, Y., Yuan, X., Jia, W., & Huang, Z. (2023). Surrogate modeling for long-term and high-resolution prediction of building thermal load with a metric-optimized KNN algorithm. *Energy and Built Environment*, 4(6), 709-724.
- Maitlo, A. K., Shaikh, R. A., & Arain, R. H. (2024). A novel dataset of date fruit for inspection and classification. *Data in Brief*, 52, 110026.
- Pariyasto, S. (2025). Analisis ontologis performa metode Euclidean, Manhattan, dan Minkowski untuk identifikasi kemiripan citra. *Journal of science and social research*, 8(1), 676-684.
- Rastin, N., Jahromi, M. Z., & Taheri, M. (2021). A generalized weighted distance k-nearest neighbor for multi-label problems. *Pattern Recognition*, 114, 107526.
- Schmitz, T. (2024). Physics-informed KNN milling stability model with process damping effects. *Journal of Manufacturing Processes*, 120, 1124-1129.
- Ujianto, N. T., Fadillah, H., Fanti, A. P., Saputra, A. D., & Ramadhan, I. G. (2025). Penerapan algoritma K-Nearest Neighbors (KNN) untuk klasifikasi citra medis. *IT-Explore: Jurnal Penerapan Teknologi Informasi dan Komunikasi*, 4(1), 33-43.
- Vinoth, R., & Sasireka, R. (2023). Ultrasound Kidney Images with IKNN-Dependent FPGA Abnormality Classification. *Journal of Circuits, Systems and Computers*, 32(04), 2350064.
- Xu, C., & Fan, Z. (2025). A performance-driven multi-stage KNN approach for local adaptive classification. *Applied Soft Computing*, 175, 113070.
- Xu, Q. (2025). Application of an intelligent English text classification model with improved KNN algorithm in the context of big data in libraries. *Systems and Soft Computing*, 7, 200186.