



Klasifikasi tingkat kematangan buah Tomat berbasis Pengolahan Citra Digital menggunakan metode k-Nearest Neighbors

Classification of Tomato Ripeness Levels Based on Digital Image Processing Using the K-Nearest Neighbors Method

Roni Denggan Pakpahan & Rizki Muliono*

Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

*Corresponding Email: ronidhiyapakpahan32@gmail.com

Abstrak

Penelitian ini bertujuan mengklasifikasikan tingkat kematangan buah tomat berdasarkan citra digital menggunakan algoritma *K-Nearest Neighbor* (KNN). Dataset yang digunakan terdiri atas 1.200 citra tomat yang terbagi ke dalam tiga kelas, yaitu tomat mentah, setengah matang, dan matang, dengan masing-masing kelas berjumlah 400 citra. Tahapan penelitian meliputi praproses citra, ekstraksi fitur warna menggunakan ruang warna HSV (*Hue, Saturation, Value*), ekstraksi fitur tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM), penggabungan fitur, pembagian data secara *stratified* menjadi 80% data latih dan 20% data uji, serta klasifikasi menggunakan KNN dengan variasi nilai *K*. Kinerja model dievaluasi menggunakan *accuracy, precision, recall, F1-score*, dan *confusion matrix*. Hasil pengujian menunjukkan bahwa model KNN menghasilkan akurasi sebesar 94,58%, dengan nilai rata-rata *precision, recall*, dan *F1-score* masing-masing sebesar 0,95. Pada tingkat kelas, tomat setengah matang memperoleh *precision* 0,98, *recall* 1,00, dan *F1-score* 0,99; tomat mentah memperoleh masing-masing 0,96, 0,90, dan 0,93; sedangkan tomat matang memperoleh 0,90, 0,94, dan 0,92. Hasil *confusion matrix* menunjukkan bahwa kesalahan klasifikasi terutama terjadi pada kelas tomat matang dan tomat mentah, sedangkan seluruh citra tomat setengah matang pada data uji berhasil diklasifikasikan dengan benar. Hasil penelitian menunjukkan bahwa kombinasi fitur HSV dan GLCM dapat digunakan sebagai representasi fitur untuk klasifikasi tingkat kematangan tomat menggunakan KNN pada dataset yang digunakan.

Kata Kunci: *K-Nearest Neighbor*; Klasifikasi Kematangan Tomat; Pengolahan Citra Digital; HSV; GLCM

Abstract

This study aims to classify tomato ripeness levels from digital images using the *K-Nearest Neighbor* (KNN) algorithm. The dataset consists of 1,200 tomato images divided into three classes: unripe, semi-ripe, and ripe, with 400 images in each class. The research stages include image preprocessing, color feature extraction using the HSV (*Hue, Saturation, Value*) color space, texture feature extraction using the *Gray Level Co-occurrence Matrix* (GLCM), feature combination, stratified splitting into 80% training data and 20% testing data, and classification using KNN with different *K* values. Model performance was evaluated using *accuracy, precision, recall, F1-score*, and a *confusion matrix*. The experimental results show that the KNN model achieved an accuracy of 94.58%, with average *precision, recall*, and *F1-score* values of 0.95. At the class level, the semi-ripe tomato class achieved a *precision* of 0.98, *recall* of 1.00, and *F1-score* of 0.99; the unripe class achieved 0.96, 0.90, and 0.93, respectively; while the ripe class achieved 0.90, 0.94, and 0.92. The *confusion matrix* shows that misclassifications mainly occurred between the ripe and unripe classes, whereas all semi-ripe tomato images in the test set were classified correctly. These results indicate that the combination of HSV and GLCM features can be used as a feature representation for tomato ripeness classification using KNN on the dataset used in this study.

Keywords: *K-Nearest Neighbor*; Tomato Ripeness Classification; Digital Image Processing; HSV; GLCM



PENDAHULUAN

Tomat (*Solanum lycopersicum* L.) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi (Jual) tinggi dan banyak dimanfaatkan sebagai bahan pangan maupun bahan baku industri. setiapTingkat kematangan tomat menjadi faktor penting yang memengaruhi kualitas, daya simpan, cita rasa, serta nilai jual produk. Dalam Proses praktiknya, sortasi kematangan tomat masih banyak dilakukan secara manual dengan mengandalkan pengamatan visual [1]. Cara tersebut relatif mudah diterapkan, tetapi sangat bergantung pada pengalaman serta ketelitian petani sehingga hasil penilaian sering kali tidak konsisten. Perbedaan kondisi pencahayaan, tingkat kelelahan, dan subjektivitas pengamat dapat menyebabkan terjadinya kekeliruan dalam proses klasifikasi, terutama ketika jumlah tomat yang harus disortir cukup banyak.

Dalam dunnia Perkembangan teknologi pengolahan citra digital memberikan peluang untuk meningkatkan efisiensi dan objektivitas untuk melakukan identifikasi kualitas hasil pertanian. Melalui pengolahan citra, gambar (Gambar) karakteristik visual suatu objek, seperti warna, tekstur, dan bentuk, dapat diekstraksi menjadi informasi yang dapat diolah oleh sistem komputer [2]. Pendekatan ini telah banyak dimanfaatkan pada berbagai penelitian di bidang pertanian karena mampu menghasilkan proses identifikasi yang lebih cepat, konsisten, dan mengurangi ketergantungan terhadap penilaian manusia [3]. Seiring berkembangnya kecerdasan buatan, pengolahan citra digital juga semakin sering dipadukan dengan algoritma klasifikasi untuk meningkatkan akurasi pengambilan keputusan.

Salah satu algoritma klasifikasi yang banyak digunakan adalah *K-Nearest Neighbor* (KNN). Algoritma ini bekerja dengan mengelompokkan data berdasarkan kedekatan jarak terhadap sejumlah tetangga terdekat sehingga termasuk metode yang sederhana, mudah diimplementasikan, dan memiliki performa yang baik pada berbagai permasalahan klasifikasi [4]. Bukan hanya itu, KNN tidak memerlukan proses pelatihan model yang kompleks sehingga sesuai diterapkan pada data dengan jumlah atribut yang relatif sedikit. Beberapa penelitian menunjukkan bahwa algoritma KNN mampu memberikan tingkat akurasi yang tinggi dalam pengenalan objek berbasis citra apabila didukung oleh proses ekstraksi fitur yang tepat.

Meskipun pengolahan citra digital dan algoritma klasifikasi telah banyak diterapkan dalam identifikasi kualitas produk pertanian, klasifikasi tingkat kematangan tomat masih memiliki beberapa permasalahan yang perlu diperhatikan. Salah satu permasalahan utama adalah adanya kemiripan karakteristik visual antar tingkat kematangan, khususnya pada tomat yang berada pada fase peralihan dari mentah menuju matang. Perubahan warna pada permukaan tomat tidak selalu berlangsung secara seragam sehingga satu tingkat kematangan dapat memiliki variasi warna yang cukup besar. Selain itu, karakteristik tekstur permukaan tomat juga dapat memberikan informasi tambahan dalam membedakan tingkat kematangan. Kondisi tersebut menunjukkan bahwa



penggunaan satu jenis karakteristik visual saja belum tentu cukup untuk merepresentasikan perbedaan antar kelas secara optimal.

Untuk mengatasi permasalahan tersebut, penelitian ini memanfaatkan karakteristik warna dan tekstur sebagai fitur dalam proses klasifikasi. Informasi warna diekstraksi menggunakan ruang warna *Hue, Saturation, Value* (HSV) karena mampu merepresentasikan karakteristik warna objek melalui komponen rona, tingkat kejenuhan warna, dan intensitas kecerahan. Sementara itu, karakteristik tekstur diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) yang dapat menghasilkan informasi mengenai pola hubungan tingkat keabuan antar piksel pada citra. Penggabungan kedua jenis fitur tersebut diharapkan dapat memberikan representasi citra yang lebih informatif dibandingkan hanya menggunakan karakteristik warna atau tekstur secara terpisah.

Selanjutnya, fitur hasil ekstraksi digunakan sebagai masukan bagi algoritma *K-Nearest Neighbor* (KNN). KNN menentukan kelas suatu data berdasarkan kedekatannya terhadap sejumlah data latih dengan menggunakan ukuran jarak tertentu. Karakteristik KNN yang sederhana dan tidak memerlukan pembentukan model parametrik yang kompleks menjadikannya relevan untuk digunakan pada penelitian dengan jumlah fitur yang relatif terbatas. Namun, performa KNN sangat dipengaruhi oleh kualitas representasi fitur dan pemilihan nilai *K*. Oleh karena itu, penggunaan fitur warna HSV yang dikombinasikan dengan fitur tekstur GLCM menjadi bagian penting dalam penelitian ini untuk menghasilkan representasi karakteristik citra yang dapat membedakan tingkat kematangan tomat.

Berdasarkan kondisi tersebut, masih diperlukan penelitian yang mengkaji penerapan kombinasi fitur warna dan tekstur dalam klasifikasi tingkat kematangan tomat menggunakan algoritma KNN. Penelitian ini secara khusus menggunakan citra tomat yang dikelompokkan ke dalam tiga tingkat kematangan, yaitu tomat mentah, setengah matang, dan matang. Tahapan penelitian mencakup praproses citra, ekstraksi fitur warna menggunakan HSV, ekstraksi fitur tekstur menggunakan GLCM, penggabungan fitur, pembagian data menjadi data latih dan data uji, serta klasifikasi menggunakan KNN dengan beberapa variasi nilai *K*. Kinerja klasifikasi kemudian dievaluasi menggunakan *accuracy, precision, recall, F1-score*, dan *confusion matrix*.

Dengan demikian, penelitian ini bertujuan untuk menerapkan kombinasi fitur HSV dan GLCM pada algoritma KNN dalam mengklasifikasikan tingkat kematangan buah tomat berdasarkan citra digital. Kontribusi penelitian terletak pada pemanfaatan karakteristik warna dan tekstur secara bersamaan sebagai representasi fitur untuk membedakan tiga tingkat kematangan tomat. Hasil penelitian diharapkan dapat memberikan informasi mengenai kemampuan kombinasi fitur tersebut dalam mendukung proses klasifikasi kematangan tomat secara lebih objektif dan konsisten pada dataset yang digunakan. Hasil tersebut selanjutnya dapat menjadi dasar bagi penelitian lanjutan mengenai

pengembangan sistem sortasi berbasis citra digital dengan mempertimbangkan kondisi pencahayaan, variasi objek, dan lingkungan pengambilan citra yang lebih beragam.

METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif untuk mengklasifikasikan tingkat kematangan buah tomat menggunakan algoritma K-Nearest Neighbor (KNN). Data yang digunakan dalam penelitian berupa dataset citra digital buah tomat yang diperoleh dari sumber data terbuka (*open source*) melalui platform Kaggle. Dataset terdiri atas 1.200 citra yang dikelompokkan ke dalam tiga kategori tingkat kematangan, yaitu tomat mentah, tomat setengah matang, dan tomat matang, dengan masing-masing kategori berjumlah 400 citra. Dataset tersebut digunakan sebagai bahan penelitian untuk membangun dan mengevaluasi model klasifikasi berbasis pengolahan citra digital.

Tabel 1. Dataset Tomat



Contoh penerapan GLCM pada dataset:

Parameter penelitian:

Distance = 1

Angle = 0°

Pemasangan piksel:

Baris pertama

Baris Pertama	(1,2),(2,2),(2,3)
Baris Ke Dua	(2,2),(2,3),(3,3)
Baris Ke Tiga	(1,2),(2,3),(3,2)
Baris Ke Empat	(1,1),(1,2),(2,2)
Jumlah	12

Penyusunan Matriks GLCM:

Gray Level	1	2	3
1	3	3	0
2	0	3	3
3	0	1	1

Keterangan

Misalnya

- pasangan (1,2) muncul 3 kali
- pasangan (2,3) muncul 3 kali
- pasangan (3,2) muncul 1 kali

Normalisasi GLCM:

$$P(i,j) = \frac{GLCM(i,j)}{\sum_i \sum_j rGLCM(i,j)}$$

Jumlah seluruh elemen: =12

Maka:

$$P = \begin{bmatrix} 0.083 & 0.250 & 0 \\ 0 & 0.250 & 0.250 \\ 0 & 0.083 & 0.083 \end{bmatrix}$$

Perhitungan GLCM:

Rumus Contrast:

$$\text{Contrast} = \sum_i \sum_j (i - j)^2 P(i,j)$$

$= (1-1)^2 (0.083)$
$+ (1-2)^2 (0.250)$
$+ (2-2)^2 (0.250)$
$+ (2-3)^2 (0.250)$
$+ (3-2)^2 (0.083)$
$+ (3-3)^2 (0.083)$
$= 0 + 0.250 + 0 + 0.250 + 0.083 + 0$
Contrast = 0.583

Rumus Energy:

$$\text{Energy} = \sum_i \sum_j P(i,j)^2$$

Perhitungan:

$= (0.083)^2$
$+ (0.250)^2$
$+ (0.250)^2$
$+ (0.250)^2$
$+ (0.083)^2$
$+ (0.083)^2$
$= 0.0069 + 0.0625 + 0.0625 + 0.0625 + 0.0069 + 0.0069$
Energy = 0.208

Homogeneity:

Rumus:

$$\text{Homogeneity} = \sum_i \sum_j \frac{P(i,j)}{1 + |i - j|}$$

Perhitungan:

$$= 0.083 + \frac{0.250}{2} + 0.250 + \frac{0.250}{2} + \frac{0.083}{2} + 0.083$$

$$= 0.083 + 0.125 + 0.250 + 0.125 + 0.041 + 0.083$$

$$\text{Homogeneity} = 0.707$$

Vektor Fitur:

Hasil Ekstraksi fitur						
Hue	Saturation	Value	Contrast	Energy	Homogeneity	Corelation
0.52	0.71	0.84	0.583	0.208	0.707	0.792

Perhitungan Manual KNN:

$$K = 3$$

Feature Vektor Citra Uji

$$(0.52, 0.71, 0.84, 0.583, 0.208, 0.707, 0.792)$$

Dibandingkan dengan data training:

Data	Kelas	Jarak
D15	Matang	0.231
D84	Matang	0.287
D177	Setengah Matang	0.342


Jarak dihitung menggunakan Euclidean Distance

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

Karena **2 dari 3 tetangga terdekat** berasal dari kelas **Tomat Matang**, maka hasil klasifikasi adalah

Tomat Matang

Perangkat yang digunakan dalam penelitian meliputi komputer atau laptop sebagai media pemrosesan data, sedangkan perangkat lunak yang digunakan adalah Python dengan pustaka OpenCV untuk pengolahan citra, NumPy dan Pandas untuk pengolahan data, Scikit-learn untuk implementasi algoritma KNN, serta Scikit-image untuk ekstraksi fitur tekstur menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Visualisasi hasil pengujian dilakukan menggunakan Matplotlib dan Seaborn.



Gambar 1. Flowchart Klasifikasi KNN

Rancangan penelitian terdiri atas beberapa tahapan, yaitu pengumpulan dataset, praproses citra, ekstraksi fitur, pembentukan model klasifikasi, pengujian model, dan evaluasi hasil. Pada tahap praproses, seluruh citra diseragamkan ukurannya menjadi 224×224 piksel. Selanjutnya dilakukan ekstraksi fitur warna menggunakan ruang warna HSV (*Hue, Saturation, Value*) dan ekstraksi fitur tekstur menggunakan metode GLCM. Fitur yang dihasilkan kemudian digabungkan menjadi satu vektor fitur sebagai masukan bagi algoritma KNN. Teknik pengambilan sampel menggunakan seluruh data citra yang tersedia pada dataset (*total sampling*). 639 sebesar 80% dan data uji sebesar 20% menggunakan metode *train-test split* dengan pembagian secara *stratified* agar proporsi setiap kelas tetap seimbang.

Variabel bebas dalam penelitian ini adalah fitur warna HSV dan fitur tekstur GLCM yang diekstraksi dari citra tomat, sedangkan variabel terikat berupa hasil klasifikasi tingkat kematangan tomat yang terdiri atas kelas mentah, setengah matang, dan matang. Teknik pengumpulan data dilakukan melalui proses ekstraksi karakteristik visual dari

setiap citra, kemudian data fitur digunakan sebagai masukan pada proses pelatihan dan pengujian model KNN.

Analisa data dilakukan menggunakan algoritma *K-Nearest Neighbor* [5]. dengan pengujian beberapa nilai parameter *K* untuk memperoleh model dengan performa terbaik. Evaluasi kinerja model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil evaluasi digunakan untuk menilai kemampuan model dalam mengklasifikasikan tingkat kematangan tomat berdasarkan karakteristik warna dan tekstur citra digital. Dengan pendekatan tersebut, diperoleh model klasifikasi yang dapat digunakan sebagai pendukung proses sortasi tomat secara otomatis dengan tingkat

HASIL DAN PEMBAHASAN

Proses Penelitian ini menghasilkan model klasifikasi tingkat kematangan tomat menggunakan algoritma *K-Nearest Neighbor* (KNN) berdasarkan kombinasi fitur warna HSV dan fitur tekstur GLCM. Setelah melalui tahapan praproses citra, dan proses ekstraksi fitur, serta pembentukan model menggunakan data training, dilakukan pengujian terhadap data validasi untuk mengetahui kemampuan model dalam mengenali tiga kategori kematangan tomat, yaitu mentah, setengah matang, dan matang.

Hasil evaluasi menunjukkan bahwa model mampu memberikan performa klasifikasi yang baik. Tingkat akurasi yang diperoleh mencapai 94,58%, sehingga sebagian besar citra tomat pada data uji berhasil dikenali sesuai dengan kelas sebenarnya. Nilai tersebut menunjukkan bahwa kombinasi fitur warna dan tekstur mampu merepresentasikan karakteristik setiap tingkat kematangan dengan baik sehingga proses klasifikasi dapat dilakukan secara efektif.

Tabel 2 Hasil Evaluasi Model Klasifikasi KNN

Parameter Evaluasi	Nilai
Akurasi	94,58%
Precision (Macro Average)	0,95
Recall (Macro Average)	0,95
F1-Score (Macro Average)	0,95
Precision (Weighted Average)	0,95
Recall (Weighted Average)	0,95
F1-Score (Weighted Average)	0,95

Berdasarkan Tabel 1, model menunjukkan kemampuan klasifikasi yang konsisten pada seluruh kelas. Kesesuaian nilai rata-rata *precision*, *recall*, dan *F1-score* mengindikasikan bahwa model tidak hanya mampu mengenali data secara keseluruhan, tetapi juga memiliki keseimbangan dalam mengidentifikasi masing-masing kategori kematangan tomat. Kondisi tersebut menunjukkan bahwa penggunaan fitur warna HSV yang dikombinasikan dengan fitur tekstur GLCM mampu meningkatkan kemampuan algoritma KNN dalam membedakan karakteristik visual setiap kelas.



Evaluasi lebih lanjut dilakukan terhadap setiap kategori kematangan untuk mengetahui kemampuan model dalam mengidentifikasi masing-masing kelas secara individual. Hasil evaluasi tersebut disajikan pada Tabel 2. ketepatan

Tabel 3. Peforma Klasifikasi Setiap kelas yang Tinggi


Kelas	Precision	Recall	F1-Score
Tomat Mentah	0,96	0,90	0,93
Tomat Setengah Matang	0,98	1,00	0,99
Tomat Matang	0,90	0,94	0,92

Berdasarkan Tabel 2, kelas tomat setengah matang memberikan performa terbaik dibandingkan dua kelas lainnya. Hal tersebut menunjukkan bahwa karakteristik warna dan tekstur pada fase tersebut memiliki pola yang lebih mudah dikenali oleh algoritma KNN. Sementara itu, kelas tomat mentah dan tomat matang juga menunjukkan kemampuan klasifikasi yang baik meskipun masih ditemukan beberapa data yang memiliki kemiripan karakteristik visual. Kondisi ini dapat dipengaruhi oleh perubahan warna yang berlangsung secara bertahap selama proses pematangan sehingga sebagian citra memiliki karakteristik yang saling mendekati.

Untuk mengetahui distribusi hasil prediksi pada setiap kelas, dilakukan evaluasi menggunakan *confusion matrix*. Matriks ini digunakan untuk melihat hubungan antara kelas aktual dan hasil prediksi model sehingga dapat diketahui pola kesalahan klasifikasi yang terjadi.

Tabel 4. Matrix Hasil perhitungan Klasifikasi KNN

Kelas Aktual	Prediksi Tomat Matang	Prediksi Tomat Mentah	Prediksi Tomat Setengah Matang
Tomat Matang	75	3	2
Tomat Mentah	8	72	0
Tomat Setengah Matang	0	0	80



Gambar 2. Gambar Confusion Matrix KNN

Berdasarkan Tabel 3, sebagian besar citra tomat berhasil diklasifikasikan sesuai dengan kelas aktualnya. Seluruh citra tomat setengah matang dikenali dengan benar sehingga tidak ditemukan kesalahan klasifikasi pada kelas tersebut. Hasil ini menunjukkan bahwa karakteristik warna dan tekstur tomat setengah matang memiliki pola yang lebih mudah dibedakan dibandingkan kelas lainnya.

Kesalahan klasifikasi masih ditemukan pada kelas tomat matang dan tomat mentah. Beberapa citra tomat matang diprediksi sebagai tomat mentah maupun tomat setengah matang. Sebaliknya, sejumlah citra tomat mentah diprediksi sebagai tomat matang. Kondisi tersebut mengindikasikan adanya kemiripan karakteristik visual pada sebagian citra, terutama pada warna permukaan buah yang berada pada fase transisi kematangan atau dipengaruhi oleh kondisi pencahayaan saat proses akuisisi citra.

Meskipun demikian, jumlah kesalahan klasifikasi relatif kecil dibandingkan jumlah data yang berhasil diprediksi dengan benar. Hal tersebut sejalan dengan nilai akurasi model sebesar 94,58%, yang menunjukkan bahwa algoritma *K-Nearest Neighbor* mampu mengenali tingkat kematangan tomat secara konsisten. Kombinasi fitur warna HSV dan fitur tekstur GLCM memberikan representasi yang baik terhadap karakteristik setiap kelas sehingga model dapat digunakan sebagai alternatif untuk mendukung proses sortasi tomat secara otomatis.

SIMPULAN

Berdasarkan hasil penelitian, algoritma *K-Nearest Neighbor* (KNN) mampu mengklasifikasikan tingkat kematangan tomat berdasarkan karakteristik warna dan tekstur citra digital secara efektif. Kombinasi fitur warna HSV dan fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) memberikan representasi yang baik terhadap perbedaan karakteristik setiap tingkat kematangan sehingga model dapat membedakan tomat mentah, setengah matang, dan matang dengan tingkat ketepatan yang tinggi. Hasil pengujian menunjukkan bahwa sebagian besar citra berhasil dikenali sesuai dengan kelas sebenarnya, meskipun masih ditemukan sejumlah kecil kesalahan klasifikasi pada kelas yang memiliki karakteristik visual yang saling mendekati. Temuan ini menunjukkan bahwa pendekatan pengolahan citra digital yang dipadukan dengan algoritma KNN dapat menjadi alternatif yang andal untuk mendukung proses identifikasi tingkat kematangan tomat secara otomatis. Penerapan metode ini berpotensi meningkatkan efisiensi, konsistensi, dan objektivitas proses sortasi dibandingkan dengan pengamatan secara manual. Oleh karena itu, model yang dihasilkan dapat dijadikan sebagai dasar dalam pengembangan sistem sortasi tomat berbasis kecerdasan buatan yang lebih praktis dan adaptif untuk mendukung kegiatan pascapanen maupun penerapan di sektor pertanian modern.



DAFTAR PUSTAKA

- [1] Y. Mardianto, T. Dewi, and P. Risma, "Analisis Klasifikasi Kematangan Buah Tomat dengan Pendekatan Transfer Learning Model EfficientNet," vol. 11, no. 1, pp. 20–25, 2024.
- [2] M. B. Sulthan, I. Wahyudi, and T. Informasi, "Klasifikasi Kematangan Buah Tomat Menggunakan Fitur RGB dan HSI Berbasis BACKPROPAGATION," vol. 4, no. 1, pp. 84–95, 2023.
- [3] K. N. N. Untuk, K. Seleksi, and P. Beasiswa, "Implementasi Algoritma Klasifikasi K-Nearest Neighbor," vol. 6, no. 2, pp. 118–127, 2021.
- [4] P. L. Jatika, J. Supriyanto, D. Alita, and A. R. Isnain, "Penerapan Algoritma K-Nearest Neighbor (K-NN) Untuk Analisis Sentimen Publik Terhadap Pembelajaran Daring," vol. 4, pp. 74–80, 2023.
- [5] A. Ainun, D. Halim, and S. Anraeni, "Analisis Klasifikasi Dataset Citra Penyakit Pneumonia Menggunakan Metode K- Nearest Neighbor (KNN)," vol. 2, no. 1, pp. 1–12, 2021.

