

IMPLEMENTASI ALGORITMA K-NEAREST NEIGHBOR (KNN) UNTUK KLASIFIKASI MUTU TELUR BERDASARKAN FITUR WARNA DAN TEKSTUR

Ardiansyah Aswin, Zulfahmi Indra, Debi Yandra Niska

Ilmu Komputer, Universitas Negeri Medan

Jl. Willem Iskandar Ps. V Medan, Indonesia

aswinardiansyah06@gmail.com

ABSTRAK

Telur ayam menjadi salah satu sumber protein hewani yang memiliki peranan penting bagi masyarakat Indonesia, namun hingga saat ini proses penilaian mutunya masih dominan dilakukan secara manual sehingga berpotensi menimbulkan subjektivitas, ketidakkonsistenan hasil, serta kurang efisien, khususnya pada proses produksi berskala besar di sektor industri. Penelitian ini bertujuan untuk merancang dan mengembangkan sistem klasifikasi mutu telur ayam ras secara otomatis berbasis pengolahan citra dengan memanfaatkan algoritma K-Nearest Neighbor (KNN). Dataset awal terdiri dari 400 citra telur yang dikelompokkan ke dalam empat kelas mutu, yaitu sangat bersih, bersih, sedikit kotor, dan kotor. Untuk meningkatkan keragaman data, jumlah citra diperbanyak menjadi 3200 melalui proses augmentasi berupa rotasi 0° , $\pm 15^\circ$, 30° , serta flip horizontal. Tahapan pra-pemrosesan meliputi segmentasi objek telur menggunakan metode thresholding pada ruang warna HSV yang dikombinasikan dengan operasi morfologi guna memperjelas pemisahan objek dari latar belakang. Proses ekstraksi fitur dilakukan dengan menghitung nilai rata-rata Hue, Saturation, dan Value sebagai representasi fitur warna, serta fitur tekstur yang terdiri dari contrast, correlation, energy, dan homogeneity menggunakan pendekatan Gray Level Co-occurrence Matrix (GLCM). Seluruh fitur yang diperoleh kemudian dinormalisasi menggunakan Min-Max Scaler sebelum dilakukan proses klasifikasi. Berdasarkan hasil validasi silang, pemilihan nilai K sebesar 3 menghasilkan akurasi rata-rata sebesar 89%. Selanjutnya, model yang dikembangkan diimplementasikan ke dalam sebuah website sehingga pengguna dapat mengunggah citra telur dan memperoleh hasil klasifikasi mutu secara otomatis, objektif, dan efisien.

Kata kunci : HSV, GLCM, K-Nearest Neighbor (KNN), Telur, Website

1. PENDAHULUAN

Industri peternakan unggas, terutama pada sektor produksi telur, memegang peranan strategis dalam memenuhi kebutuhan protein hewani bagi masyarakat, sehingga mutu telur menjadi aspek krusial yang perlu diperhatikan secara serius dalam tahapan produksi maupun distribusi [1, 2]. Berdasarkan data Badan Pusat Statistik (BPS) Sumatera Utara, produksi telur pada periode 2021–2024 mengalami fluktuasi namun secara umum menunjukkan tren peningkatan. Kondisi tersebut menuntut adanya sistem pengendalian mutu yang mampu menjamin kualitas telur agar sesuai dengan standar dan layak dikonsumsi oleh masyarakat.

Untuk menjaga standar mutu telur, telah ditetapkan Standar Nasional Indonesia (SNI) 3926:2008 dan SNI 3926:2023 yang mengatur parameter penilaian mutu telur, meliputi kebersihan kerabang, bentuk telur, serta kondisi internal telur [3]. Salah satu indikator mutu yang mudah diamati adalah warna kerabang telur. Warna kerabang dipengaruhi oleh pigmen alami serta kondisi penyimpanan, di mana telur dengan kerabang coklat yang bersih umumnya menunjukkan mutu yang lebih baik dibandingkan telur dengan kerabang kusam atau kotor [4, 5].

Namun demikian, proses klasifikasi mutu telur yang masih dilakukan secara manual memiliki berbagai kelemahan, seperti subjektivitas penilaian, ketergantungan pada pengalaman petugas, serta kurang efisien apabila diterapkan pada produksi dalam

skala besar [6]. Selain itu, penilaian manual berpotensi menimbulkan ketidakkonsistenan hasil sortasi sehingga dapat menurunkan kualitas produk yang didistribusikan. Oleh karena itu, diperlukan suatu sistem klasifikasi otomatis berbasis teknologi yang mampu melakukan penilaian mutu telur secara objektif, cepat, dan konsisten.

Warna dan tekstur kerabang telur menjadi parameter penting dalam penilaian mutu karena mencerminkan kondisi pakan, umur penyimpanan, serta kualitas telur secara keseluruhan [1]. Perkembangan teknologi machine learning memungkinkan pemanfaatan pengolahan citra digital untuk melakukan klasifikasi mutu telur secara otomatis. Salah satu algoritma yang banyak digunakan dalam proses klasifikasi adalah K-Nearest Neighbor (KNN) karena memiliki konsep yang sederhana, mudah diimplementasikan, serta mampu memberikan hasil prediksi yang cukup baik [7, 8].

Pada penelitian ini, klasifikasi mutu telur dilakukan melalui pengolahan citra dengan mengekstraksi fitur warna dan tekstur dari kerabang telur. Ekstraksi fitur warna dilakukan menggunakan ruang warna HSV (*Hue Saturation Value*) karena lebih sesuai dengan persepsi visual manusia dalam membedakan spektrum warna dibandingkan dengan ruang warna RGB [9]. Sementara itu, ekstraksi fitur tekstur dilakukan menggunakan metode Gray Level Co-occurrence Matrix (GLCM) untuk menganalisis

pola tekstur kerabang telur melalui fitur *contrast*, *correlation*, *homogeneity*, dan *energy* [10, 11]. Kombinasi penggunaan fitur HSV dan GLCM terbukti mampu menghasilkan akurasi klasifikasi yang lebih baik dibandingkan dengan penggunaan salah satu metode secara terpisah [12].

Penelitian sebelumnya menunjukkan bahwa metode K-Nearest Neighbor (KNN) mampu mengklasifikasikan telur puyuh berdasarkan warna dan tekstur dengan tingkat akurasi sebesar 77,78% [6]. Berdasarkan hasil tersebut, penelitian ini bertujuan untuk merancang dan menerapkan sistem klasifikasi mutu telur berbasis pengolahan citra digital menggunakan kombinasi fitur HSV dan GLCM serta algoritma KNN. Sistem yang dikembangkan diharapkan mampu meningkatkan akurasi, efisiensi, dan konsistensi dalam proses sortasi mutu telur, sehingga dapat mendukung peningkatan kualitas produk dalam industri peternakan unggas.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian sebelumnya yaitu, mengembangkan sistem klasifikasi citra buah mengkudu dengan menerapkan algoritma K-Nearest Neighbor (KNN) yang memanfaatkan fitur warna dari ruang warna HSV serta fitur tekstur yang diekstraksi menggunakan metode Gray Level Co-occurrence Matrix (GLCM). Penelitian ini menunjukkan bahwa penggunaan kombinasi fitur warna dan tekstur mampu menghasilkan tingkat akurasi klasifikasi yang paling tinggi, yaitu mencapai 95%, sehingga membuktikan bahwa integrasi fitur HSV dan GLCM sangat efektif dalam meningkatkan performa klasifikasi citra digital [13].

Penelitian serupa juga dilakukan oleh sumari dkk dalam mengembangkan sistem klasifikasi mutu telur burung puyuh berbasis citra digital dengan menggunakan algoritma K-Nearest Neighbor (KNN) yang menggabungkan fitur warna dan tekstur melalui pendekatan fusi informasi. Sistem yang dikembangkan mampu mengklasifikasikan mutu telur ke dalam tiga kategori, yaitu baik, sedang, dan buruk, dengan tingkat akurasi rata-rata sebesar 77,78%. Hasil penelitian ini menunjukkan bahwa penerapan fusi fitur tidak hanya meningkatkan akurasi klasifikasi, tetapi juga memperbaiki efisiensi proses dibandingkan dengan metode yang tidak menggunakan fusi informasi [6].

2.2. Telur dan Karakteristiknya

Telur adalah salah satu sumber protein hewani yang penting karena memiliki kandungan gizi yang lengkap, meliputi protein, lemak esensial, vitamin A, D, E, dan B kompleks, serta berbagai mineral yang berperan dalam mendukung fungsi tubuh dan menjaga sistem kekebalan tubuh [4]. Produktivitas ayam petelur dipengaruhi oleh kualitas pullet, manajemen pemeliharaan, dan pakan, yang diukur melalui

konsumsi ransum, hen day production, feed conversion ratio (FCR), serta tingkat.

Proses pembentukan telur berlangsung selama 24–26 jam melalui tahapan ovulasi, pembentukan albumen, membran, hingga pembentukan cangkang sebagai fase terlama sebelum telur dikeluarkan melalui kloaka [14, 15]. Secara struktural, telur terdiri dari cangkang berbahan kalsium karbonat sebagai pelindung, albumen yang mengandung air dan protein pelindung, serta kuning telur yang kaya lipid dan vitamin [16].

2.3. Citra Digital dan Pengolahan Citra

Citra adalah representasi visual dua dimensi yang tersusun dari piksel dan banyak digunakan dalam berbagai bidang, seperti pengenalan pola dan analisis visual [17]. Citra digital dapat diproses oleh komputer karena setiap piksel memiliki nilai intensitas atau warna tertentu, seperti pada ruang warna RGB atau HSV [18, 19]. Jenis citra digital meliputi citra biner, grayscale, dan true color yang digunakan sesuai kebutuhan analisis [20, 21]. Pengolahan citra mencakup proses peningkatan kualitas, segmentasi, dan analisis objek [22].

2.4. Ekstraksi Fitur Citra

Ekstraksi fitur adalah proses untuk memperoleh karakteristik penting dari citra agar dapat digunakan dalam pengenalan atau klasifikasi objek [23]. Kualitas fitur sangat memengaruhi kinerja sistem klasifikasi karena fitur menjadi representasi utama dari objek. Teknik ekstraksi fitur yang umum digunakan meliputi fitur warna, tekstur, dan bentuk, yang banyak diterapkan pada aplikasi computer vision dan kecerdasan buatan [24].

2.5. Saturation Value (HSV)

HSV adalah model ruang warna yang terdiri dari Hue, Saturation, dan Value, yang masing-masing merepresentasikan warna dasar, tingkat kejenuhan, dan kecerahan [25, 26]. Model ini lebih sesuai dengan persepsi visual manusia dibandingkan RGB sehingga banyak digunakan dalam analisis dan klasifikasi warna. Oleh karena itu, HSV sering dimanfaatkan dalam sistem klasifikasi berbasis citra, termasuk penilaian mutu telur berdasarkan warna kerabang.

2.6. Gray Level Co-occurrence Matrix (GLCM)

GLCM adalah metode statistik yang digunakan untuk menganalisis tekstur citra dengan menghitung hubungan spasial antar piksel berdasarkan arah dan jarak tertentu [10]. Dari matriks GLCM dapat dihasilkan fitur tekstur seperti *contrast*, *correlation*, *energy*, dan *homogeneity*. Metode ini banyak digunakan karena mampu merepresentasikan pola tekstur secara efektif untuk keperluan klasifikasi dan pengenalan objek [27].

2.7. Machine Learning dan Supervised Learning

Machine learning adalah bagian dari kecerdasan buatan yang memungkinkan sistem belajar dari data untuk menghasilkan prediksi atau keputusan secara otomatis [28]. Salah satu pendekatannya adalah supervised learning, yaitu pembelajaran menggunakan data berlabel untuk mempelajari hubungan antara input dan output [29]. Metode ini umum digunakan pada permasalahan klasifikasi dan prediksi.

2.8. Supervised Learning

Supervised learning adalah metode pembelajaran mesin yang menggunakan data berlabel, di mana setiap data input memiliki output yang benar sehingga algoritma dapat mempelajari hubungan antara keduanya dan menghasilkan fungsi yang mampu memetakan input ke output secara akurat. Metode ini memungkinkan model mengklasifikasikan atau memprediksi data baru berdasarkan pola yang telah dipelajari, dan performanya akan meningkat seiring bertambahnya jumlah data pelatihan berlabel. Beberapa algoritma yang termasuk dalam supervised learning antara lain K-Nearest Neighbors (K-NN), Linear Regression, Naïve Bayes, Neural Network, Support Vector Machines (SVM), Logistic Regression, serta Decision Tree dan Random Forest.

2.9. K-Nearest Neighbor (KNN)

K-Nearest Neighbor (KNN) adalah algoritma supervised learning yang bersifat non-parametrik dan bekerja dengan menyimpan seluruh data latih. KNN mengklasifikasikan data baru berdasarkan mayoritas kelas dari K tetangga terdekat menggunakan metrik jarak seperti Euclidean Distance [29]. Pemilihan nilai K sangat berpengaruh terhadap performa model karena dapat menyebabkan overfitting atau underfitting jika tidak tepat. Rumus perhitungan jarak yang digunakan adalah Euclidean Distance sebagaimana ditunjukkan pada rumus berikut [29].

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

Rumus Euclidean Distance Keterangan :

$d(x, y)$ = jarak kedekatan antara data x ke data y

x_i = data testing (data uji) ke n

y_i = data training (data latih) ke i

n = jumlah atribut 1 sampai n

Algoritma K-Nearest Neighbor (K-NN) memiliki beberapa kelebihan, di antaranya mudah diterapkan dan dipahami, mampu mempelajari batas keputusan non-linier baik untuk klasifikasi maupun regresi, serta tidak memerlukan proses pelatihan eksplisit karena perhitungan dilakukan pada saat prediksi. Selain itu, data baru dapat ditambahkan tanpa pelatihan ulang dan algoritma ini mendukung berbagai jenis metrik jarak sesuai kebutuhan. Namun, K-NN juga memiliki

beberapa kekurangan, seperti kompleksitas perhitungan yang tinggi pada dataset besar karena seluruh data pelatihan harus digunakan saat prediksi, serta semakin tidak efisien pada data berdimensi tinggi. K-NN juga sensitif terhadap outlier dan dapat menghasilkan prediksi yang kurang akurat ketika jarak antar data berbeda pada beberapa dimensi, sehingga algoritma menganggap semua dimensi memiliki tingkat kedekatan yang sama.

2.10. Confusion Matrix

Confusion matrix digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi dan data aktual [30]. Matriks ini terdiri dari True Positive, True Negative, False Positive, dan False Negative, yang digunakan untuk menghitung metrik evaluasi seperti akurasi, precision, recall, dan F1-score guna menilai performa model secara menyeluruh.

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

$$precision = \frac{TP}{TP + FP} \quad (3)$$

$$recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

3. METODE PENELITIAN

3.1. Jenis dan Objek Penelitian

Jenis penelitian ini adalah penelitian kuantitatif yang bertujuan untuk mengembangkan model klasifikasi mutu telur ayam menggunakan algoritma K-Nearest Neighbor (KNN) berdasarkan fitur warna dan tekstur yang diekstraksi dari citra telur. Penelitian ini menggunakan variabel independen berupa fitur warna HSV (Hue, Saturation, Value) dan fitur tekstur GLCM (energy, contrast, correlation, dan homogeneity), serta variabel dependen berupa mutu telur ayam yang dikategorikan menjadi empat kelas: sangat baik, baik, sedang, dan buruk. Populasi penelitian adalah seluruh telur ayam dengan variasi mutu berdasarkan kondisi fisik warna dan tekstur cangkang, sementara sampelnya terdiri dari 400 citra digital telur ayam ras yang telah diberi label mutu. Fitur yang diekstraksi dari citra digunakan sebagai input dalam pembangunan model klasifikasi berbasis KNN, dan kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score.

3.2. Instrumen Penelitian

Instrumen penelitian yang digunakan meliputi perangkat keras berupa kamera smartphone iPhone 12 Pro untuk pengambilan citra telur ayam dan laptop Asus untuk pengolahan data serta implementasi algoritma, serta perangkat lunak berupa Python dengan pustaka OpenCV untuk pemrosesan citra dan Scikit-learn untuk klasifikasi menggunakan algoritma K-Nearest Neighbor (KNN).

3.3. Pengumpulan Data

Tahapan awal penelitian ini dimulai dengan pengumpulan data citra telur ayam melalui observasi lapangan guna memperoleh informasi visual yang akurat dan relevan. Proses pengambilan data dilakukan selama dua bulan dengan mempertimbangkan variasi pencahayaan dan kondisi lingkungan untuk memastikan kualitas serta keberagaman citra. Citra yang dikumpulkan mencakup berbagai tingkat mutu telur agar mendukung akurasi proses klasifikasi berbasis fitur warna dan tekstur.

3.4. Preprocessing

Pada tahap ini, citra telur ayam negeri yang telah dikumpulkan terlebih dahulu diberi label secara manual sesuai kategori mutu (mutu 1 sangat baik, mutu 2 baik, mutu 3 sedang, dan mutu 4 buruk) berdasarkan karakteristik visual seperti warna dan tekstur permukaan. Setelah proses pelabelan, citra digital melalui tahap pre-processing berupa perubahan ukuran, penghapusan latar belakang, normalisasi, serta augmentasi dengan rotasi 15° untuk meningkatkan variasi data. Tahapan ini dilakukan guna meningkatkan kualitas citra dan memastikan fitur penting dapat diekstraksi secara optimal pada proses berikutnya.

3.5. Feature Extraction

Setelah tahap pre-processing, penelitian dilanjutkan dengan ekstraksi fitur menggunakan metode Hue Saturation Value (HSV) untuk memperoleh informasi warna berupa hue, saturation, dan value, serta metode Gray Level Co-occurrence Matrix (GLCM) untuk mengekstraksi fitur tekstur berdasarkan hubungan spasial antar piksel tingkat keabuan. Proses ini menghasilkan data numerik yang merepresentasikan karakteristik warna dan tekstur dari setiap citra, di mana kedua metode tersebut dipilih karena mampu menyoroti atribut visual penting pada kulit telur yang relevan dalam proses klasifikasi mutu.

3.6. Pembagian Data

Pada penelitian ini, pembagian data dilakukan menggunakan metode 5-Fold Cross Validation untuk memperoleh evaluasi model yang lebih objektif dan stabil, terutama karena jumlah dataset yang terbatas. Data hasil ekstraksi fitur dibagi menjadi lima bagian, di mana masing-masing bagian secara bergantian digunakan sebagai data uji sementara sisanya menjadi data latih, dan proses ini diulang hingga setiap fold digunakan sebagai data uji. Hasil evaluasi dari seluruh fold kemudian dirata-ratakan untuk menghasilkan performa model yang lebih representatif, sehingga metode ini memungkinkan pengujian yang lebih menyeluruh terhadap kemampuan algoritma K-Nearest Neighbor (KNN) dalam mengklasifikasikan mutu telur berdasarkan fitur warna dan tekstur.

3.7. K-Nearest Neighbor (K-NN)

Setelah proses pembagian data selesai, tahap berikutnya adalah melakukan klasifikasi mutu telur menggunakan algoritma K-Nearest Neighbor (KNN), yaitu algoritma supervised learning yang menentukan kelas data uji berdasarkan kedekatan jarak dengan sejumlah data tetangga terdekat. Pada tahap ini, data fitur dari citra pelatihan digunakan untuk membentuk model, sedangkan data fitur dari citra pengujian digunakan untuk menguji performanya. Beberapa nilai parameter k diuji, yaitu $k = 3, 5, 7$, dan 9 , untuk menentukan nilai yang memberikan hasil paling optimal, dengan perhitungan jarak menggunakan metode Euclidean distance. Proses klasifikasi kemudian menghasilkan prediksi kategori mutu telur (mutu 1, mutu 2, mutu 3, atau mutu 4) berdasarkan mayoritas label dari tetangga terdekat.

3.8. Evaluasi Model

Tahap akhir penelitian ini adalah evaluasi performa model KNN yang telah dibangun menggunakan metrik accuracy, precision, recall, dan F1-score, yang dihitung dengan membandingkan hasil prediksi model terhadap label sebenarnya pada data uji. Evaluasi dilakukan pada setiap variasi parameter untuk menentukan skenario dengan performa terbaik sekaligus menilai efektivitas kombinasi fitur warna HSV dan tekstur GLCM dalam proses klasifikasi. Melalui tahap ini, dapat diketahui sejauh mana model KNN mampu melakukan generalisasi dengan baik terhadap data baru.


3.9. Pembuatan Sistem Berbasis Web

Tahap ini mencakup proses pembangunan sistem berbasis web menggunakan VSCode sebagai editor teks dan Flask sebagai framework Python. Pengembangan dimulai dengan pembuatan antarmuka menggunakan template Bootstrap yang diatur melalui file HTML dan CSS, kemudian dilanjutkan dengan integrasi fitur agar sistem dapat berfungsi secara optimal. Pada tahap ini, fungsi input dan output juga dikembangkan dan dihubungkan melalui file Python untuk memungkinkan interaksi antara pengguna dan sistem secara dinamis.

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data


Data dalam penelitian ini berupa citra telur ayam yang diambil langsung dari Peternakan Johan di Kecamatan Sei Bambi, Kabupaten Serdang Bedagai, Sumatera Utara, selama periode 25 Agustus 2025 hingga 24 September 2025. Sebanyak 400 citra dikumpulkan dan dibagi secara merata ke dalam empat kelas mutu, yaitu Mutu 1, Mutu 2, Mutu 3, dan Mutu 4. Setiap kelas didokumentasikan melalui citra (Gambar 1 hingga Gambar 4) yang mewakili kondisi visual telur berdasarkan kategori mutu yang telah ditentukan.



Gambar 1. Citra mutu telur ayam

4.2. Resize & Cropping

Data citra yang telah dikumpulkan memiliki ukuran beragam sehingga dilakukan proses resize menjadi 256×256 piksel agar seragam. Selanjutnya, dilakukan cropping untuk menghilangkan bagian yang tidak relevan dan memfokuskan citra pada objek telur ayam. Contoh hasil proses ini ditunjukkan pada Gambar 2.



Gambar 2. Hasil resize & cropping pada citra telur ayam

4.3. Background Removal

Proses background removal dilakukan secara manual menggunakan perangkat lunak pengedit gambar untuk menghilangkan elemen yang tidak diperlukan agar analisis lebih terfokus pada objek telur ayam. Hasil penerapan tahap ini ditunjukkan pada Gambar 3.




Gambar 3. Hasil background removal pada citra telur ayam

4.4. Augmentasi

Dalam penelitian ini dilakukan augmentasi citra untuk memperbesar ukuran dataset dengan menerapkan transformasi seperti rotasi 15° , flip horizontal, zoom, dan perubahan kecerahan. Dataset awal berjumlah 400 citra (masing-masing 100 citra per kelas), dan setiap citra di-augmentasi sebanyak delapan kali sehingga total dataset meningkat menjadi 3.200 citra.

4.5. Hue, Saturation, & Value (HSV)

Pada tahapan ekstraksi fitur warna HSV, citra RGB dikonversi menjadi HSV untuk memperoleh nilai Hue, Saturation, dan Value sebagai indikator mutu telur. Langkah-langkahnya yaitu membaca citra menggunakan `cv2.imread()`, mengubah format BGR ke RGB dengan `cv2.cvtColor()`, lalu mengkonversinya ke HSV. Selanjutnya dihitung nilai rata-rata Hue, Saturation, dan Value hanya pada area telur menggunakan masking. Hasil ekstraksi ini kemudian digunakan sebagai input model K-Nearest Neighbors.




Gambar 4. Visualisasi distribusi nilai HSV

Berdasarkan Gambar 4, distribusi nilai Hue menunjukkan perbedaan warna antar kelas mutu, di mana Mutu 1 dan 2 memiliki median lebih rendah dibanding Mutu 3 dan 4. Pada fitur Saturation terlihat kenaikan bertahap dari Mutu 1 hingga Mutu 4, menunjukkan warna kulit semakin jenuh seiring meningkatnya mutu. Sementara untuk Value, Mutu 1 memiliki median tertinggi dan Mutu 3–4 lebih rendah, menandakan telur bermutu rendah cenderung lebih gelap. Secara keseluruhan, Hue menggambarkan variasi warna, Saturation menunjukkan intensitas warna, dan Value menunjukkan tingkat kecerahan, sehingga kombinasi fitur HSV efektif membedakan kelas mutu telur dan dapat digunakan dalam klasifikasi berbasis warna.

4.6. Gray Level Co-occurrence Matrix (GLCM)

GLCM digunakan untuk memperoleh informasi terkait pola dan permukaan citra telur ayam dengan empat fitur statistik: contrast, homogeneity, energy, dan correlation. Tahapannya meliputi mengonversi citra ke grayscale menggunakan `cv.cvtColor()`, menghitung matriks GLCM dengan `greycomatrix()` menggunakan parameter `distance = 1` dan sudut 0° , kemudian menghitung fitur statistik menggunakan `graycoprops()`. Hasilnya digunakan sebagai input fitur pada model klasifikasi K-Nearest Neighbors.



Gambar 5. Visualisasi nilai distribusi fitur GLCM

Berdasarkan Gambar 4.5, distribusi fitur GLCM menunjukkan variasi antar kelas mutu. Pada fitur Contrast, Mutu 1 dan 2 memiliki nilai median lebih rendah dibanding Mutu 3 dan 4. Fitur Correlation menunjukkan pola berbeda, dengan Mutu 2 memiliki

median tertinggi, diikuti Mutu 3, sementara Mutu 1 dan 4 lebih rendah. Pada fitur Energy, Mutu 4 memiliki median tertinggi, menunjukkan keseragaman permukaan yang lebih tinggi dibanding kelas lainnya. Sementara pada Homogeneity, Mutu 2 dan Mutu 3 memiliki median tertinggi, menandakan tekstur lebih seragam. Secara keseluruhan, fitur Contrast dan Homogeneity menggambarkan tingkat kehalusan permukaan, Correlation menunjukkan keteraturan pola tekstur, dan Energy menunjukkan keseragaman citra. Kombinasi fitur ini memberikan gambaran lengkap karakteristik tekstur setiap kelas mutu dan berpotensi meningkatkan akurasi klasifikasi ketika dikombinasikan dengan fitur warna HSV.

4.7. Pembagian Data

Pada penelitian ini digunakan metode 5-Fold Cross Validation untuk pembagian data. Teknik ini dipilih karena memberikan evaluasi model yang lebih objektif dan stabil dibandingkan metode pembagian data konvensional. Dengan 5-Fold, model diuji lima kali dengan kombinasi data latih dan uji yang berbeda. Rincian pembagian data ditampilkan pada Tabel 1

Tabel 1. Pembagian Data 5-Fold

Fold ke-	Data Latih		Data Uji	
	Fold	Jumlah Data	Fold	Jumlah Data
1	Fold 2, 3, 4, 5	2.560	Fold 1	640
2	Fold 1, 3, 4, 5	2.560	Fold 2	640
3	Fold 1, 2, 4, 5	2.560	Fold 3	640
4	Fold 1,2, 3, 5	2.560	Fold 4	640
5	Fold 1, 2, 3, 4	2.560	Fold 5	640

4.8. K-Nearest Neighbors (K-NN)

Setelah proses pra-pemrosesan data dilakukan, tahap berikutnya adalah membangun model klasifikasi menggunakan algoritma *K-Nearest Neighbors* (K-NN). K-NN adalah metode supervised learning yang mengelompokkan data uji berdasarkan tingkat kemiripannya (jarak terdekat) dengan sejumlah data tetangga terdekat (k). Pada tahap ini, nilai k yang menjadi parameter awal harus ditentukan terlebih dahulu. Perhitungan jarak menggunakan metode *Euclidean Distance*. Dalam penelitian ini dilakukan pengujian dengan beberapa nilai k , yaitu $k = 3, 5, 7$, dan 9, untuk memperoleh nilai k terbaik sebagai model akhir.

Untuk mendapatkan model paling optimal, dilakukan evaluasi menggunakan *K-Fold Cross Validation*. Teknik ini membagi dataset menjadi beberapa *fold*. Pada penelitian ini digunakan *5-Fold*, sehingga dataset dibagi menjadi lima bagian, dimana satu fold digunakan sebagai data uji dan empat lainnya sebagai data latih secara bergantian. Dengan demikian, seluruh data memperoleh kesempatan yang sama menjadi data uji, sehingga hasil evaluasi lebih reliabel dan mengurangi bias.

Sebagai ilustrasi, dilakukan perhitungan manual proses klasifikasi mutu telur ayam menggunakan algoritma K-NN. Contoh data latih dan data uji ditampilkan pada Tabel 2 dan Tabel 3. Seluruh data pada tabel tersebut adalah dataset yang telah melalui proses normalisasi menggunakan metode Min-Max Scaler.

Tabel 1. Sampel Data Latih

No	H	S	V	Constras	Correlation	Energy	Homogenity	Kategori
1	0,27	0,47	0,67	0,85	0,45	0,02	0,39	Mutu 1
2	0,21	0,32	0,6	0,78	0,68	0,01	0,23	Mutu 1
3	0,2	0,61	0,95	0,53	0,77	0,04	0,18	Mutu 1
4	0,25	0,36	0,31	0,54	0,58	0,22	0,39	Mutu 2
5	0,59	0,4	0,38	0,15	0,68	0,09	0,5	Mutu 2
6	0,57	0,44	0,35	0,15	0,68	0,17	0,45	Mutu 2
7	0,26	0,7	0,45	0,89	0,15	0,01	0,15	Mutu 3
8	0,52	0,53	0,56	0,41	0,73	0,04	0,3	Mutu 3
9	0,4	0,55	0,23	0,23	0,55	0,27	0,51	Mutu 3
10	0,41	0,55	0,48	0,75	0,53	0,15	0,23	Mutu 4
11	1	0,64	0,14	0,87	0,15	0,3	0,27	Mutu 4
12	0,52	0,54	0,35	0,66	0,54	0,24	0,26	Mutu 4

Tabel 2. Sampel Data Uji

No	H	S	V	Constras	Correlation	Energy	Homogenity	Kategori
N	0.08	0.89	0.54	0.48	0.65	0.05	0.15	?

Kemudian dilakukan perhitungan jarak dengan *Euclidean Distance* antara uji dengan data latih, yang akan ditampilkan dalam Tabel 4. Setelah perhitungan *Euclidean Distance* dilakukan untuk setiap data, nilai

jarak disusun mulai dari yang terkecil hingga terbesar. Hasil pengurutan jarak tersebut ditampilkan pada Tabel 4.

Tabel 3. Perhitungan Jarak

No	Euclidean Distance	Hasil	Kategori
1	$\sqrt{(0.08 - 0.27)^2 + (0.89 - 0.47)^2 + (0.54 - 0.67)^2 + (0.48 - 0.85)^2 + (0.65 - 0.45)^2 + (0.05 - 0.02)^2 + (0.15 - 0.39)^2}$	0,681762	Mutu 1
2	$\sqrt{(0.08 - 0.21)^2 + (0.89 - 0.32)^2 + (0.54 - 0.6)^2 + (0.48 - 0.78)^2 + (0.65 - 0.68)^2 + (0.05 - 0.01)^2 + (0.15 - 0.23)^2}$	0,666558	Mutu 1
3	$\sqrt{(0.08 - 0.2)^2 + (0.89 - 0.61)^2 + (0.54 - 0.95)^2 + (0.48 - 0.53)^2 + (0.65 - 0.77)^2 + (0.05 - 0.04)^2 + (0.15 - 0.18)^2}$	0,528015	Mutu 1
4	$\sqrt{(0.08 - 0.25)^2 + (0.89 - 0.36)^2 + (0.54 - 0.31)^2 + (0.48 - 0.54)^2 + (0.65 - 0.58)^2 + (0.05 - 0.22)^2 + (0.15 - 0.39)^2}$	0,676535	Mutu 2
5	$\sqrt{(0.08 - 0.59)^2 + (0.89 - 0.4)^2 + (0.54 - 0.38)^2 + (0.48 - 0.15)^2 + (0.65 - 0.68)^2 + (0.05 - 0.09)^2 + (0.15 - 0.5)^2}$	0,871608	Mutu 2
6	$\sqrt{(0.08 - 0.57)^2 + (0.89 - 0.44)^2 + (0.54 - 0.35)^2 + (0.48 - 0.15)^2 + (0.65 - 0.68)^2 + (0.05 - 0.17)^2 + (0.15 - 0.45)^2}$	0,832406	Mutu 2
7	$\sqrt{(0.08 - 0.26)^2 + (0.89 - 0.7)^2 + (0.54 - 0.45)^2 + (0.48 - 0.89)^2 + (0.65 - 0.15)^2 + (0.05 - 0.01)^2 + (0.15 - 0.15)^2}$	0,704486	Mutu 3
8	$\sqrt{(0.08 - 0.52)^2 + (0.89 - 0.53)^2 + (0.54 - 0.56)^2 + (0.48 - 0.41)^2 + (0.65 - 0.73)^2 + (0.05 - 0.04)^2 + (0.15 - 0.3)^2}$	0,597913	Mutu 3
9	$\sqrt{(0.08 - 0.4)^2 + (0.89 - 0.55)^2 + (0.54 - 0.23)^2 + (0.48 - 0.23)^2 + (0.65 - 0.55)^2 + (0.05 - 0.27)^2 + (0.15 - 0.51)^2}$	0,751399	Mutu 3
10	$\sqrt{(0.08 - 0.41)^2 + (0.89 - 0.55)^2 + (0.54 - 0.48)^2 + (0.48 - 0.75)^2 + (0.65 - 0.53)^2 + (0.05 - 0.15)^2 + (0.15 - 0.23)^2}$	0,576021	Mutu 4
11	$\sqrt{(0.08 - 1)^2 + (0.89 - 0.64)^2 + (0.54 - 0.14)^2 + (0.48 - 0.87)^2 + (0.65 - 0.15)^2 + (0.05 - 0.3)^2 + (0.15 - 0.27)^2}$	1,244146	Mutu 4
12	$\sqrt{(0.08 - 0.52)^2 + (0.89 - 0.54)^2 + (0.54 - 0.35)^2 + (0.48 - 0.66)^2 + (0.65 - 0.54)^2 + (0.05 - 0.24)^2 + (0.15 - 0.26)^2}$	0,667008	Mutu 4

Tabel 4. Pengurutan jarak

No.	Euclidean Distance	Pengurutan	Kategori
1	0,681762	7	Mutu 1
2	0,666558	4	Mutu 1
3	0,528015	1	Mutu 1
4	0,676535	6	Mutu 2
5	0,871608	11	Mutu 2
6	0,832406	10	Mutu 2
7	0,704486	8	Mutu 3
8	0,597913	3	Mutu 3
9	0,751399	9	Mutu 3
10	0,576021	2	Mutu 4
11	1,244146	12	Mutu 4
12	0,667008	5	Mutu 4

Pada contoh perhitungan manual ini, nilai k yang digunakan adalah 7, karena pada k = 3 dan k = 5 terjadi


hasil voting yang seimbang. Penentuan kelas mayoritas dengan nilai k = 7 ditunjukkan pada Tabel 6

Tabel 5. Penentuan kategori mayoritas

Euclidean Distance	Pengurutan	Kategori
0,528015	1	Mutu 1
0,576021	2	Mutu 4
0,597913	3	Mutu 3
0,666558	4	Mutu 1
0,667008	5	Mutu 4
0,676535	6	Mutu 2
0,681762	7	Mutu 1


Berdasarkan Tabel 6, kategori Mutu 1 memperoleh 2 suara, Mutu 2 mendapat 1 suara, Mutu 3 mendapat 1 suara, dan Mutu 4 memperoleh 2 suara, sehingga kategori Mutu 1 menjadi mayoritas. Dengan demikian, data uji N diklasifikasikan sebagai Mutu 1.

Hasil perbandingan akurasi untuk setiap nilai k pada 5 fold ditampilkan pada Gambar 6



Gambar 6. Perbandingan akurasi per-fold untuk setiap nilai k

Berdasarkan Gambar 6, nilai akurasi untuk setiap K (3, 5, 7, dan 9) menunjukkan pola yang stabil di seluruh lima fold, menandakan bahwa proses K-Fold Cross Validation berjalan konsisten tanpa variasi signifikan antar fold. Untuk hasil evaluasi yang lebih rinci ditunjukkan pada Gambar 7.




Gambar 7. Heatmap akurasi kombinasi k dan fold

Berdasarkan Gambar 7, seluruh kombinasi nilai K dan fold menghasilkan akurasi tinggi dan konsisten, berada pada rentang 0.82–0.90. Nilai K = 3 dan K = 5 memberikan performa terbaik dengan akurasi tertinggi masing-masing 0.908 dan 0.906, sementara K = 7 dan K = 9 sedikit lebih rendah. Pola warna yang seragam menunjukkan stabilitas model di seluruh fold. Secara keseluruhan, nilai K yang lebih kecil khususnya K = 3 memberikan hasil paling optimal dan konsisten. Dengan demikian, K = 3 dipilih sebagai parameter terbaik dan digunakan sebagai konfigurasi akhir dalam klasifikasi mutu telur ayam.

Evaluasi performa model K-Nearest Neighbors (K-NN) menggunakan nilai k terbaik, yaitu k = 3. Hasil evaluasi ditunjukkan melalui confusion matrix pada Gambar 8 dan classification report pada Tabel 7.

Berdasarkan confusion matrix, model menunjukkan tingkat kesalahan yang rendah. Pada kelas Mutu 1, sebanyak 392 dari 400 data diprediksi dengan benar, dengan sedikit kesalahan ke Mutu 2 dan Mutu 3. Kelas Mutu 2 memperoleh 366 prediksi benar dari 400 data, sedangkan kelas Mutu 3 memperoleh 376 prediksi benar. Pada kelas Mutu 4, terdapat 381

data yang terklasifikasi dengan tepat, dengan kesalahan minor pada kelas Mutu lain.



Gambar 8. Heatmap confusion matrix

Tabel 6. Classification report

	Precision	Recall	F1-score	Support
Mutu 1	0.90	0.98	0.94	800
Mutu 2	0.86	0.83	0.84	800
Mutu 3	0.89	0.87	0.88	800
Mutu 4	0.93	0.90	0.91	800
Accuracy			0.89	3200
Macro avg	0.89	0.89	0.89	3200
Weighted avg	0.89	0.89	0.89	3200

Hasil ini diperkuat oleh classification report pada tabel. Precision berada pada rentang 0.86–0.93, recall 0.83–0.98, dan f1-score 0.84–0.94. Secara keseluruhan, model memperoleh akurasi 89% dengan rata-rata precision, recall, dan f1-score sebesar 0.89. Nilai ini menunjukkan bahwa model dapat melakukan prediksi secara akurat, konsisten mendeteksi setiap kelas, serta menjaga keseimbangan performa.

Dengan hasil tersebut, dapat disimpulkan bahwa algoritma K-NN dengan k = 3 memberikan performa klasifikasi yang baik pada citra telur ayam. Kinerja model stabil di seluruh kelas mutu, menunjukkan bahwa pemilihan nilai k optimal berperan penting, di mana nilai yang lebih besar cenderung menurunkan akurasi, sedangkan k = 3 memberikan hasil paling seimbang dan optimal dalam penelitian ini.

4.9. Pembuatan Sistem Berbasis Web

Pembuatan sistem berbasis web dilakukan untuk memfasilitasi peternak dalam mengecek mutu telur ayam secara mudah. Sistem ini bertujuan mempermudah proses klasifikasi mutu telur yang menggunakan algoritma K-Nearest Neighbors (K-NN) dengan ekstraksi fitur warna HSV dan tekstur GLCM.

Sistem memungkinkan pengguna mengunggah citra telur ayam, menganalisis mutu, dan menerima hasil klasifikasi. Tampilan dibuat sederhana agar dapat digunakan oleh peternak tanpa latar belakang teknis.

Pengembangan sistem menggunakan VSCode sebagai code editor dan Flask sebagai framework Python untuk menghubungkan model klasifikasi dengan antarmuka pengguna. Template website open-source dari GitHub digunakan sebagai dasar tampilan dan dimodifikasi sesuai kebutuhan. Website menampilkan informasi mengenai implementasi algoritma pada halaman utama dan menyediakan fitur prediksi pada halaman khusus seperti pada Gambar 8




Gambar 8. Tampilan halaman utama website

Pada alurnya, pengguna menekan tombol “Coba Prediksi” untuk menuju halaman unggah citra seperti pada Gambar 9. Pengguna mengunggah gambar melalui fitur “Choose File”, kemudian citra diproses pada backend melalui ekstraksi fitur, normalisasi sesuai preprocessing, dan klasifikasi menggunakan model K-NN. Hasil prediksi ditampilkan bersama citra dan nilai fitur, sebagaimana ditunjukkan pada Gambar 10.



Gambar 9. Tampilan halaman utama website



Gambar 10. Tampilan hasil klasifikasi

Tampilan website terdiri dari tiga bagian utama: halaman utama berisi informasi penelitian, halaman prediksi untuk unggah gambar, dan halaman hasil prediksi. Website ini mudah digunakan karena proses klasifikasi cukup dengan mengunggah gambar, namun

masih memiliki keterbatasan karena hasil prediksi sangat bergantung pada kualitas citra input.

4.10. Analisis Hasil Pengujian

Berdasarkan hasil pengujian menggunakan metode Black Box Testing, sistem klasifikasi mutu telur terbukti berjalan dengan baik dan stabil. Proses klasifikasi memberikan hasil yang akurat dan sesuai dengan performa model K-Nearest Neighbors (KNN) pada tahap pelatihan. Sistem juga memiliki kemampuan error handling yang baik, seperti memberikan peringatan ketika pengguna tidak mengunggah citra atau mengunggah citra yang tidak sesuai. Dengan hasil tersebut, sistem dinilai layak digunakan untuk membantu identifikasi mutu telur secara otomatis berbasis citra digital

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian mengenai klasifikasi mutu telur ayam menggunakan algoritma K-Nearest Neighbors (K-NN) dengan ekstraksi fitur warna HSV dan tekstur GLCM, diperoleh bahwa metode ini mampu mengklasifikasikan telur ke dalam empat kelas mutu dengan akurasi terbaik sebesar 89% pada nilai $k = 3$ menggunakan 5-fold cross validation. Kombinasi fitur HSV dan GLCM juga terbukti efektif karena mampu memberikan informasi komprehensif terkait warna dan pola permukaan telur, sehingga menghasilkan nilai precision, recall, dan f1-score rata-rata sebesar 0.89. Namun, penelitian ini masih memiliki keterbatasan dalam jumlah dan variasi dataset sehingga ke depannya disarankan untuk menambah jumlah data serta menguji algoritma lain seperti SVM, Random Forest, atau Deep Learning (CNN) untuk memperoleh performa yang lebih optimal.

DAFTAR PUSTAKA

- [1] S. Mutiar, D. Arziyah, and M. Anggia, “Karakteristik Kualitas Telur Komersial Berdasarkan Ekterior Dan Interior Dari Berbagai Jenis Telur,” *Gontor Agrotech Sci. J.*, vol. 8, no. 3, pp. 130–137, 2023, doi: 10.21111/agrotech.v8i3.9573.
- [2] P. Worang, E. H. B. Sondakh, C. K. M. Palar, D. B. J. Rumondor, and I. Wahyuni, “Kualitas telur ayam ras yang dijual di pasar tradisional dan pasar modern Kota Manado,” *Zootec*, vol. 42, no. 2, p. 138, 2022, doi: 10.35792/zot.42.1.2022.41479.
- [3] A. Jalil and R. Hidayat, “Sistem Deteksi Mutu Telur Ayam Ras Menggunakan Sensor Ldr (Light Dependent Resistor) Berbasis Arduino Uno,” *Teknokom*, vol. 7, no. 1, pp. 197–204, 2024, doi: 10.31943/teknokom.v7i1.180.
- [4] Z. Wulandari and I. I. Arief, “Review: Tepung Telur Ayam: Nilai Gizi, Sifat Fungsional dan Manfaat,” *J. Ilmu Produksi dan Teknol. Has. Peternak.*, vol. 10, no. 2, pp. 62–68, 2022, doi: 10.29244/jipthp.10.2.62-68.

- [5] N. Pratiwi, Ti. Sartika, and Komarudin, "Pengaruh Warna Kerabang Telur Terhadap Kualitas Telur Ayam KUB-2," *Pros. Semin. Teknol. dan Agribisnis Peternak. VIII-Webinar*, pp. 698–703, 2021.
- [6] A. D. W. Sumari, P. I. Mawarni, and A. R. Syulistyo, "Klasifikasi Mutu Telur Burung Puyuh Berdasarkan Warna dan Tekstur Menggunakan Metode K-Nearest Neighbor (KNN) dan Fusi Informasi," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 5, pp. 1019–1028, 2021, doi: 10.25126/jtiik.2021854393.
- [7] S. Hajar *et al.*, "Comparative Analysis of K-Nearest Neighbor and Support Vector Machine Methods for Assessing Quality Standards of Palm Oil Bunches," vol. 2, no. x, 2024.
- [8] Z. F. Siti Nuril Maghfiratus Sholeha, "Implementasi Metode K-Nearest Neighbor dalam Sistem Rekomendasi Film Berdasarkan Preferensi Pengguna," vol. 2, no. 10, pp. 1–23, 2024.
- [9] D. Giuliani, "Metaheuristic Algorithms Applied to Color Image Segmentation on HSV Space," *J. Imaging*, vol. 8, no. 1, 2022, doi: 10.3390/jimaging8010006.
- [10] N. Iqbal, R. Mumtaz, U. Shafi, and S. M. H. Zaidi, "Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms," *PeerJ Comput. Sci.*, vol. 7, pp. 1–26, 2021, doi: 10.7717/PEERJ-CS.536.
- [11] A. D. W. Sumari, P. I. Mawarni, and A. R. Syulistyo, "Klasifikasi Mutu Telur Burung Puyuh Berdasarkan Warna dan Tekstur Menggunakan Metode K-Nearest Neighbor (KNN) dan Fusi Informasi," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 5, pp. 1019–1028, 2021, doi: 10.25126/jtiik.2021854393.
- [12] W. Shinta and C. A. Sari, "Klasifikasi Bunga Mawar Menggunakan Knn Dan Ekstraksi Fitur Glcm Dan Hsv," *Skanika*, vol. 5, no. 2, pp. 145–156, 2022, doi: 10.36080/skanika.v5i2.2951.
- [13] C. Irawan, E. H. Rachmawanto, C. Atika Sari, and R. Umah Nur, "Klasifikasi Citra Mengkudu Berdasarkan Perhitungan Jarak Piksel pada Algoritma K-Nearest Neighbour," *Infotekmesin*, vol. 14, no. 2, pp. 200–207, 2023, doi: 10.35970/infotekmesin.v14i2.1827.
- [14] C. Wen *et al.*, "Microbiota continuum along the chicken oviduct and its association with host genetics and egg formation," *Poult. Sci.*, vol. 100, no. 7, p. 101104, 2021, doi: 10.1016/j.psj.2021.101104.
- [15] A. A. Permana *et al.*, *Machine Learning*, vol. 45, no. 13, 2023. [Online]. Available: <https://books.google.ca/books?id=EoYBngEACAAJ&dq=mitchell+machine+learning+1997&hl=en&sa=X&ved=0ahUKEwiomdqfj8TkAhWGsIkKHRChAtoQ6AEIKjAA>
- [16] S. Saifullah, "Enhancement Dalam Proses Segmenasi Citra Untuk Deteksi Fertilitas Telur," vol. 9, pp. 134–145, 2020.
- [17] U. Sutar, K. K. Pandya, and H. Desai, "Advancements in Image Processing Techniques Enhancing Image Quality and Recognition Accuracy," *J. Electr. Syst. (J. Electr. Syst.)*, vol. Volume 20, pp. 7214–7221, 2024.
- [18] J. Jumadi, Y. Yupianti, and D. Sartika, "Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering," *JST (Jurnal Sains dan Teknol.)*, vol. 10, no. 2, pp. 148–156, 2021, doi: 10.23887/jstundiksha.v10i2.33636.
- [19] Ratna and Silvia, "Pengolahan Citra Digital Dan Histogram Dengan Phytan Dan Text Editor Phycharm," *Technol. J. Ilm.*, vol. 11, no. 3, p. 181, 2020, doi: 10.31602/tji.v11i3.3294.
- [20] I. Pujiyanto and D. Darwis, "UJI KETAHANAN CITRA DIGITAL TERHADAP MANIPULASI ROBUSTNESS PADA STEGANOGRAPHY," vol. 2, no. 1, pp. 16–27, 2021.
- [21] A. Herdiansah, R. I. Borman, D. Numaningsih, A. A. J. Sinlae, and R. R. Al Hakim, "Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 2, p. 388, 2022, doi: 10.30865/jurikom.v9i2.4066.
- [22] Arnita, F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. 2022. [Online]. Available: www.pustakaaksara.co.id
- [23] P. Aji and Prihati, "Evaluasi Ekstraksi Fitur Klasifikasi Teks Untuk Peningkatan Akurasi Klasifikasi Menggunakan Naive Bayes," *Elkom J. Elektron. dan Komput.*, vol. 13, no. 1, pp. 159–175, 2020, doi: 10.51903/elkom.v13i1.277.
- [24] A. A. Syahidi, *Pengolahan Citra Digital dan Dasar Visi Komputer dengan Python*. POLIBAN PRESS, 2024.
- [25] L. H. Aulia, F. Azhari, and M. Dhuha Bimantara, "Implementation of HSV Imagery with K-Nearest Neighbor for Classification of Maturity Levels in Tomatoes," *Bigint Comput. J.*, vol. 1, no. 2, 2023.
- [26] J. Zhang, H. Su, T. Zhang, H. Tian, and B. Fan, "Multi-Scale Fusion Underwater Image Enhancement Based on HSV Color Space Equalization," *Sensors*, vol. 25, no. 9, pp. 1–16, 2025, doi: 10.3390/s25092850.
- [27] Y. Park and J. M. Guldman, "Measuring continuous landscape patterns with Gray-Level Co-Occurrence Matrix (GLCM) indices: An alternative to patch metrics?," *Ecol. Indic.*, vol. 109, no. October 2019, pp. 0–36, 2020, doi: 10.1016/j.ecolind.2019.105802.
- [28] B. Srikanth Reddy, "Advancements in Machine Learning: A Comprehensive Exploration of

- Methods, Applications, and Future Perspectives,” *Int. J. Sci. Res. Eng. Technol.*, vol. 4, no. 1, pp. 01–04, 2024, doi: 10.59256/ijrsreat.20240401001.
- [29] Arnita, F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision Dan Pengolahan Citra Digital*. 2022. [Online]. Available: www.pustakaaksara.co.id
- [30] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 697–711, 2021