

## KLASIFIKASI PENYAKIT DAUN ANGGUR BERBASIS CITRA MENGGUNAKAN METODE K-NEAREST NEIGHBORS (KNN)

Eli Safitri, Ronasip Heppy Ria Sibarani, Yusiva SM Sidabutar, Dedy Kiswanto

Ilmu Komputer, Universitas Negeri Medan

Jl. William Iskandar Ps. V, Kenangan Baru, Kecamatan Percut Sei Tuan,

Kabupaten Deli Serdang, Sumatera Utara, Indonesia 20221

4223250007@mhs.unimed.ac.id

### ABSTRAK

Penurunan produktivitas dan kualitas tanaman anggur sering kali disebabkan oleh serangan penyakit pada daunnya, yang sulit dideteksi secara manual di area perkebunan yang luas. Untuk mengatasi tantangan ini, penelitian ini mengembangkan sistem deteksi penyakit daun anggur berbasis citra menggunakan metode K-Nearest Neighbors (KNN) yang bertujuan meningkatkan akurasi deteksi dan efisiensi klasifikasi penyakit. Dalam penelitian ini, gambar daun anggur yang sehat dan terinfeksi penyakit dikumpulkan dan dianalisis dengan metode ekstraksi fitur yang meliputi Local Binary Pattern (LBP) untuk tekstur, deteksi tepi Canny dan Hu Moments untuk morfologi, serta histogram warna HSV. Dengan rasio 80:20 untuk data pelatihan dan pengujian, nilai K yang bervariasi (1-5) diuji, dan hasil terbaik diperoleh pada K=1 dengan akurasi 71%. Hasil ini menunjukkan bahwa pemilihan nilai K yang optimal sangat penting untuk mencapai performa terbaik dalam klasifikasi penyakit daun anggur. Kesimpulan dari penelitian ini menunjukkan bahwa metode KNN efektif dalam mengidentifikasi penyakit daun anggur, dan disarankan untuk memilih nilai K yang optimal untuk meningkatkan akurasi dan stabilitas model pada dataset yang serupa.

**Kata kunci :** Penyakit Daun Anggur, Klasifikasi, LBP, Morfologi, KNN

### 1. PENDAHULUAN

Sebagai salah satu jenis tanaman tahunan atau perennial, tanaman anggur tumbuh secara merambat. Rantingnya unik karena dapat mengeluarkan buah yang lebat. Anggur, yang termasuk dalam keluarga Vitaceae, adalah tanaman yang umum ditanam di seluruh negara. Anda dapat mengonsumsi buah anggur secara langsung atau membuatnya menjadi makanan dan minuman.[1] Penyakit tanaman merupakan salah satu faktor utama yang mempengaruhi produktivitas dan kualitas hasil pertanian di seluruh dunia. Pada tanaman anggur, meskipun buah anggur memiliki banyak manfaat dalam dunia kesehatan—seperti kemampuannya untuk mencegah penyakit akibat radikal bebas, termasuk penyakit jantung dan kanker, serta membantu memutihkan gigi yang mengalami diskolorasi—tanaman ini juga sangat rentan terhadap serangan penyakit. Tanaman anggur yang terkena hama dan penyakit dapat mengalami penurunan pertumbuhan sebesar 40%-70%, yang berimbas pada kualitas dan kuantitas buah, termasuk rasa buah yang tidak manis dan ukuran buah yang tidak maksimal.

Penyakit pada tanaman dapat menyebabkan penurunan hasil yang signifikan dan terkadang sulit untuk dikenali secara manual, terutama di area yang luas. Pengolahan gambar dapat membantu petani mencegah penyakit. Metode K-Nearest Neighbor (KNN) digunakan dalam penelitian ini untuk mengklasifikasikan penyakit pada tanaman dengan mengekstraksi fitur yang relevan dari gambar daun.[2] Daun anggur sering kali menjadi bagian yang paling rentan terhadap serangan berbagai jenis penyakit, seperti embun tepung, karat, dan jamur lain yang dapat merusak proses fotosintesis. Kondisi ini

mengakibatkan penurunan kualitas buah, bahkan gagal panen jika tidak ditangani secara tepat. Dalam praktik pertanian tradisional, petani biasanya mengandalkan kemampuan observasi visual untuk mendeteksi penyakit tanaman. Mereka mencari gejala-gejala yang terlihat, seperti perubahan warna daun, bentuk yang tidak normal, atau pola-pola tertentu pada permukaan daun. Namun, pendekatan ini memiliki kelemahan, yaitu keterbatasan dalam hal akurasi dan kecepatan. Faktor-faktor seperti kesalahan manusia, variabilitas kondisi lingkungan, serta kesamaan gejala antara berbagai penyakit sering kali membuat deteksi dini menjadi sulit. Akibatnya, penanganan penyakit sering terlambat, yang pada gilirannya meningkatkan risiko kerugian bagi petani.

Penyakit tidak akan menyebar secara luas jika penyakit ditemukan dan diklasifikasikan dengan benar. Penyakit daun tanaman biasanya disebabkan oleh virus, jamur, dan bakteri. Untuk mengidentifikasi penyakit pada tanaman secara akurat, teknik pengolahan citra memerlukan ekstraksi ciri untuk membedakan daun yang sehat. Algoritma K-Nearest Neighbors (KNN) banyak digunakan untuk mengklasifikasikan objek berdasarkan kedekatan jarak antar data.[3] Untuk menghindari kerugian yang signifikan dalam produksi tanaman, identifikasi penyakit pada tanaman sangat penting. Perubahan warna dan bentuk fisik daun dapat membantu mengidentifikasi penyakit pada daun. Namun, luas perkebunan membuat sulit bagi petani untuk menemukan penyakit secara manual. Teknik Local Binary Pattern (LBP) dan metode klasifikasi Hutan Random telah terbukti sangat efektif untuk

menemukan penyakit pada daun tanaman dalam pengolahan citra digital.[4]

Seiring perkembangan teknologi, muncul kebutuhan akan solusi yang lebih efisien dan akurat untuk mengatasi masalah ini. Dalam beberapa tahun terakhir, pengolahan citra digital dan teknik kecerdasan buatan, khususnya machine learning, telah menunjukkan potensi besar dalam membantu identifikasi penyakit tanaman secara otomatis. Dengan pendekatan ini, gejala penyakit pada daun tanaman dapat dianalisis berdasarkan pola visual tertentu, memungkinkan sistem untuk memberikan hasil deteksi yang lebih cepat dan akurat. Identifikasi dini menggunakan teknologi ini memungkinkan petani untuk segera mengambil tindakan preventif, yang dapat meminimalisir dampak negatif pada hasil panen. Algoritma klasifikasi yang dikenal sebagai metode K-Nearest Neighbor (KNN) mengklasifikasikan objek berdasarkan jarak antara data baru dan data yang sudah ada. Algoritma ini menggunakan nilai K untuk menunjukkan jumlah tetangga terdekat yang dipertimbangkan untuk menentukan kelas data yang diuji. Algoritma ini melakukan ini dengan menghitung jarak antara data uji dan semua data pelatihan menggunakan metrik seperti jarak geometris, kemudian memilih K tetangga terdekat untuk memberikan label klasifikasi berdasarkan mayoritas dari tetangga tersebut.[5] Dalam konteks deteksi penyakit daun anggur, k-NN dapat digunakan untuk menganalisis fitur-fitur visual pada daun yang terinfeksi dan mengklasifikasikannya berdasarkan kedekatan jarak dalam ruang fitur. Salah satu keunggulan utama dari k-NN adalah kesederhanaan dan fleksibilitasnya, yang memungkinkan algoritma ini diterapkan pada berbagai jenis dataset tanpa memerlukan parameter pelatihan yang kompleks.

K-Nearest Neighbor (KNN) merupakan salah satu metode klasifikasi yang berbasis supervised learning, di mana klasifikasi dilakukan dengan menghitung jarak antara data uji dan data latih untuk menentukan kelas dari objek yang belum diketahui. Dalam metode ini, klasifikasi dilakukan dengan menghitung jarak antara data uji dan data latih untuk menentukan kelas objek yang belum diketahui. KNN mencari tetangga terdekat dari data uji berdasarkan jarak terdekat. Perhitungan jarak ini biasanya dilakukan dengan metrik seperti jarak geometri. Karena kesederhanaannya dan kemampuan untuk menangani masalah klasifikasi seperti pengenalan pola berbasis citra, metode ini digunakan secara luas. Penelitian ini menggunakan teknik KNN untuk menemukan dan mengklasifikasikan penyakit pada daun anggur. Tujuan dari penelitian ini adalah untuk membuat solusi berbasis teknologi yang dapat mencegah penyebaran penyakit lebih lanjut.[6]

## 2. TINJAUAN PUSTAKA

### 2.1. Penyakit Daun Anggur

Penyakit pada daun anggur merupakan ancaman signifikan yang berdampak besar terhadap

produktivitas tanaman ini, dengan risiko penurunan pertumbuhan hingga 40%-70%. Penyakit-penyakit ini dapat menurunkan kualitas buah, seperti menurunnya rasa manis, jumlah buah yang terbatas, dan buah yang mengisut. Tanaman anggur yang rentan terhadap serangan penyakit ini memerlukan metode deteksi dini untuk mencegah penyebaran lebih lanjut, terutama dalam upaya meningkatkan mutu dan kuantitas produksi. Penggunaan teknologi berbasis pengolahan citra digital memungkinkan identifikasi dini terhadap berbagai jenis penyakit daun anggur secara efisien. Selain itu, metode ini membantu petani untuk mengambil tindakan pencegahan yang lebih cepat, sehingga kualitas dan produktivitas tanaman anggur dapat tetap terjaga. [6]

### 2.2. Klasifikasi

Klasifikasi adalah proses membangun model yang berfungsi untuk membedakan kelas data, bertujuan memprediksi kelas dari suatu objek yang belum diketahui kelasnya (Han, 2006). Proses klasifikasi terdiri dari dua tahap utama, yaitu fase training dan pembentukan aturan klasifikasi. Pada fase training, data pelatihan dianalisis dan direpresentasikan dalam bentuk aturan klasifikasi (Han, 2006). Klasifikasi melibatkan empat komponen utama: kelas, prediktor, data pelatihan (training dataset), dan data pengujian (testing dataset). Kelas adalah label variabel dependen yang mewakili kategori pada suatu objek, seperti jenis gempa, loyalitas pelanggan, atau risiko penyakit jantung. Prediktor adalah variabel independen yang menggambarkan karakteristik data, contohnya tabungan, aset, pendapatan, konsumsi alkohol, atau kebiasaan merokok. Data pelatihan berisi nilai dan prediktor untuk menentukan kelas yang sesuai, sementara data pengujian digunakan untuk mengevaluasi akurasi model klasifikasi pada data baru.[7]


### 2.3. Morfologi

Ekstraksi morfologi adalah metode penting untuk mengidentifikasi penyakit pada daun, termasuk daun anggur, dengan menganalisis karakteristik visual seperti bentuk dan tekstur. Teknik ini mencakup fitur seperti eccentricity, solidity, rectangularity, metric, extent, dan elongation untuk mengenali perbedaan morfologi yang spesifik pada daun yang mungkin mengindikasikan infeksi [8]. Pada tahap awal, segmentasi citra dilakukan untuk memisahkan daun dari latar belakang menggunakan metode thresholding, yang sederhana namun efektif dalam mengisolasi fitur utama daun [9]. Setelah itu, fitur-fitur morfologi diekstraksi dan dianalisis menggunakan algoritma klasifikasi seperti K-Nearest Neighbor (KNN) atau Support Vector Machine (SVM). Pendekatan ini terbukti akurat dalam membedakan antara daun sehat dan terinfeksi, menjadikan ekstraksi morfologi sebagai teknik yang efektif dalam deteksi penyakit tanaman.

## 2.4. LBP

Local Binary Pattern (LBP) adalah metode ekstraksi fitur yang populer dalam analisis citra untuk identifikasi tekstur pada berbagai aplikasi, termasuk identifikasi penyakit daun. LBP berfungsi untuk mengekstrak pola tekstur lokal yang unik, yang berguna dalam mengenali perbedaan halus pada permukaan daun yang terkena penyakit. Dalam deteksi penyakit tanaman, LBP bekerja dengan mengidentifikasi variasi warna dan tekstur di permukaan daun yang biasanya menunjukkan adanya infeksi atau anomali. Sebagai contoh, penelitian menunjukkan bahwa LBP dapat membedakan berbagai penyakit berdasarkan ciri tekstur yang diperoleh dari citra daun[10]. Teknik LBP seringkali dikombinasikan dengan metode machine learning lainnya, seperti Support Vector Machine (SVM) atau Convolutional Neural Networks (CNN), untuk meningkatkan akurasi klasifikasi penyakit daun[11]. Metode ini tidak hanya digunakan untuk mendeteksi penyakit pada daun anggur, tetapi juga pada berbagai jenis tanaman, di mana LBP membantu dalam mendeteksi perbedaan morfologi antara area yang sehat dan yang terinfeksi.

## 2.5. KNN



Gambar 1. Diagram Alur Algoritma KNN

Algoritma KNN (K-Nearest Neighbors) adalah algoritma klasifikasi yang menentukan kelas sebuah objek berdasarkan data pelatihan yang jaraknya paling

dekat dengan objek tersebut. Algoritma ini merupakan metode supervised learning dan bekerja dengan cara mengukur jarak terpendek antara data uji dan data latih untuk menentukan kelas data tersebut. Setelah data dikumpulkan dalam kelompok k yang spesifik, kelas mayoritas dalam kelompok tersebut digunakan sebagai kelas prediksi untuk data uji. Algoritma ini memiliki keunggulan dalam ketahanannya terhadap data yang mengandung noise dan efektif pada data latih berjumlah besar. Namun, komputasi algoritma ini cenderung memakan waktu lama jika data latihnya sangat banyak, dan kinerjanya sangat sensitif terhadap ciri-ciri data yang redundan atau kurang relevan.[12] Diagram alur algoritma K-Nearest Neighbors (KNN) dalam klasifikasi citra daun anggur yang mengalami penyakit dapat dilihat pada gambar 1.

## 2.6. Confusion Matrix

Confusion matrix adalah tabel yang menggambarkan hasil klasifikasi, menampilkan jumlah data uji yang diklasifikasikan dengan benar dan jumlah data yang salah klasifikasi[13]. Matriks ini mencakup empat elemen utama: True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN), yang digunakan untuk mengevaluasi performa model klasifikasi.

## 2.7. Precision

Precision mengukur proporsi prediksi benar dalam suatu kelas dibandingkan dengan seluruh prediksi untuk kelas tersebut. Precision penting untuk menilai akurasi klasifikasi, terutama dalam memastikan bahwa prediksi penyakit daun tidak mengandung terlalu banyak kesalahan deteksi yang salah (false positives).

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

## 2.8. Recall

Recall menunjukkan seberapa baik model dapat mendeteksi seluruh sampel yang sebenarnya berada dalam suatu kelas. Metode ini penting untuk mengevaluasi kemampuan sistem dalam mengidentifikasi semua daun yang terinfeksi dalam setiap kelas penyakit, karena memberikan informasi tentang tingkat keberhasilan model dalam mengurangi kesalahan deteksi (false negatives).

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$


## 2.9. F1-Score

F1-Score merupakan gabungan precision dan recall, memberikan gambaran keseimbangan antara keduanya. F1-score penting karena mempertimbangkan situasi di mana precision atau recall lebih rendah, memberikan nilai rata-rata harmonis yang menunjukkan efisiensi keseluruhan model dalam mengklasifikasikan penyakit daun.

$$\text{F1-score} = \frac{2 \times \text{precision} \times \text{Recall}}{\text{precision} + \text{Recall}} \quad (3)$$

### 3. METODE PENELITIAN

Penelitian ini dilakukan untuk mengklasifikasikan penyakit pada daun anggur menggunakan pendekatan berbasis pengolahan citra dan algoritma k-NN. Dataset gambar daun anggur dengan dan tanpa penyakit dikumpulkan dan diproses menggunakan berbagai teknik ekstraksi fitur, yaitu Local Binary Pattern (LBP) untuk tekstur, fitur morfologi melalui deteksi tepi Canny dan Hu Moments, serta fitur warna melalui histogram warna ruang HSV. Seperti Flowchart yang terlihat pada Gambar 1.



Gambar 2. Diagram Alur Metode


#### 3.1. Pengumpulan data

Pada tahap ini, data citra daun anggur dikumpulkan melalui observasi langsung di lapangan. Proses pengumpulan dilakukan secara manual dengan pengambilan gambar daun anggur yang menunjukkan tanda-tanda penyakit. Data terdiri dari gambar daun anggur yang mengalami tiga jenis penyakit: jamur bulu (downy mildew), jamur karat (rust disease), dan jamur tepung (powdery mildew). Keseluruhan gambar sebanyak 400 citra yang terdiri dari 4 kelas. Dari 400 citra tersebut akan dibagi menjadi 2 bagian yaitu 80% data training dan 20% data testing. Proses pengumpulan data mencakup langkah-langkah berikut:

- Pengamatan di Lapangan:** Pengamatan dilakukan pada tanaman anggur di lokasi tertentu. Daun-daun yang menunjukkan gejala penyakit dipilih untuk didokumentasikan.
- Pengambilan Gambar:** Setiap daun yang diamati difoto menggunakan kamera dengan resolusi tinggi untuk memastikan detail tekstur dan warna daun dapat terekam dengan baik. Kamera yang

digunakan juga disesuaikan dengan kondisi pencahayaan untuk mendapatkan hasil gambar yang optimal.


- Klasifikasi Manual:** Berdasarkan pengamatan, daun-daun yang difoto kemudian diklasifikasikan secara manual menjadi tiga kelompok penyakit: jamur bulu, jamur karat, dan jamur tepung.



Gambar 3. Dataset Daun Anggur  
(a). Daun Tanpa Penyakit (b). Penyakit Jamur Karat  
(c). Penyakit Jamur Tepung  
(d). Penyakit Jamur Bulu

#### 3.2. Processing Data

Preprocessing data adalah langkah penting yang dilakukan sebelum data citra daun anggur dapat digunakan dalam model klasifikasi k-Nearest Neighbors (k-NN). Pada tahap ini, data yang telah dikumpulkan melalui observasi langsung akan diproses dan diolah sehingga lebih siap digunakan untuk pelatihan model. Preprocessing bertujuan untuk meningkatkan kualitas data dan mengekstraksi fitur-fitur penting dari citra yang dapat digunakan sebagai input bagi algoritma k-NN.



Gambar 4. Diagram Alur Pre-Processing

- Pengolahan Ukuran Citra (Resizing)**  
Citra daun anggur yang diambil melalui observasi langsung diubah ukurannya menjadi 64x64 piksel. Langkah ini bertujuan untuk menyamakan dimensi seluruh citra agar dapat diproses oleh algoritma dengan konsistensi yang baik. Pengubahan ukuran ini juga membantu mempercepat komputasi tanpa menghilangkan terlalu banyak detail penting dari citra.
- Normalisasi Citra**  
Setelah citra diproses, setiap nilai piksel dinormalisasi dengan membaginya dengan 255,

sehingga berada dalam rentang 0 hingga 1. Normalisasi ini penting untuk memastikan bahwa skala nilai tidak terlalu besar, sehingga model dapat berfungsi dengan lebih baik dan tidak terpengaruh oleh rentang nilai yang terlalu lebar.

### c. Pengubahan Citra ke Grayscale

Untuk fitur-fitur tertentu, seperti ekstraksi tekstur dan fitur morfologi, citra diubah menjadi grayscale. Pengubahan ini dilakukan karena informasi tekstur dan bentuk lebih mudah dianalisis dalam ruang warna grayscale daripada ruang warna penuh (RGB). Grayscale mengurangi dimensi data dan fokus pada intensitas cahaya, sehingga mempermudah deteksi pola.

### 3.3. Ekstraksi Fitur Tekstur (Local Binary Pattern - LBP)

Ekstraksi fitur tekstur dilakukan menggunakan metode Local Binary Pattern (LBP). Metode ini mengubah setiap piksel dalam citra grayscale menjadi pola biner berdasarkan intensitas piksel tetangganya. Hasilnya adalah histogram dari pola-pola biner yang digunakan sebagai fitur yang merepresentasikan tekstur citra daun. Fitur LBP ini penting untuk mendeteksi perubahan tekstur yang diakibatkan oleh penyakit pada daun anggur.

Fungsi LBP dapat didefinisikan pada persamaan 1:

$$LBP_{p,r}(x_c, y) = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p \quad (4)$$

Fungsi S(x) dapat didefinisikan sebagai berikut:

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (5)$$


Keterangan:

P = jumlah piksel tetangga

R = nilai radius

gc = nilai piksel x,y

gp = nilai piksel tetangga




Gambar 5. Ekstraksi Fitur LBP

### 3.4. Ekstraksi Fitur Morfologi

Fitur morfologi diekstraksi menggunakan deteksi tepi (Canny Edge Detection) untuk menangkap bentuk atau kontur dari daun yang mungkin berubah akibat infeksi penyakit. Metode Canny menggunakan teknik pengembangan atau thresholding untuk memperoleh tepi objek pada citra, sehingga batasan antar objek menjadi lebih jelas. Proses deteksi tepi ini didasarkan pada tiga kriteria yang bertujuan untuk mengoptimalkan deteksi tepi pada citra yang

mengandung noise. Kriteria pertama adalah ketepatan deteksi, yang bertujuan memaksimalkan hasil deteksi agar semua tepi teridentifikasi dengan baik tanpa ada yang terlewat. Kriteria kedua adalah lokalisasi yang baik, yang berarti bahwa tepi yang terdeteksi harus memiliki jarak yang sekecil mungkin dari posisi tepi yang sebenarnya. Kriteria ketiga adalah respon minimal, yang menegaskan bahwa hasil deteksi tidak boleh menghasilkan tepi yang tidak nyata [14]. Setelah tepi citra dideteksi, fitur bentuk lebih lanjut dihitung menggunakan Hu Moments, yang menghasilkan nilai-nilai numerik yang mencirikan bentuk atau pola dari objek dalam citra. Fitur ini berguna untuk mendeteksi perubahan morfologi yang terjadi pada daun yang terkena penyakit. Metode Canny bekerja untuk menghasilkan tepi objek menggunakan persamaan 3.

$$g(x, y) = D[Gauss(x, y) * f(x, y)] \quad (6)$$



Gambar 6. Ekstraksi Fitur Morfologi

### 3.5. Ekstraksi Fitur Warna (Histogram dalam Ruang Warna HSV)

Selain tekstur dan morfologi, warna daun juga merupakan indikator penting dari kondisi kesehatan daun. Ekstraksi fitur warna dilakukan dalam ruang warna HSV (Hue, Saturation, Value) dengan menghitung histogram untuk setiap saluran (H, S, dan V). Fitur ini menangkap perubahan warna yang mungkin timbul akibat infeksi, seperti bercak warna pada daun yang terinfeksi oleh jamur.

Persamaan yang digunakan untuk mencari fitur warna yang diperlukan dalam penelitian ini:

$$r = \frac{R}{(R+G+B)}, g = \frac{G}{(R+G+B)}, b = \frac{B}{(R+G+B)} \quad (7)$$

$$V = \max(r, g, b) \quad (8)$$

$$S = \begin{cases} 0 & \text{jika } V = 0 \\ 1 - \frac{\min(r, g, b)}{V} & \text{jika } V > 0 \end{cases} \quad (9)$$

$$H = \begin{cases} 0 & , \\ \frac{60 * (g-b)}{S * V} & , \text{jika } V = r \\ 60 * \left[ 2 + \frac{b-r}{S * V} \right] & , \text{jika } V = g \\ 60 * \left[ 2 + \frac{r-g}{S * V} \right] & , \text{jika } V = b \end{cases} \quad (10)$$

$$H = H + 360 \text{ jika } h < 0 \quad (11)$$

Keterangan:

r,g,b = Derajat keabuan dari sebuah piksel red, green dan blue

R,G,B = Citra warna red, green dan blue (0-255)

H = hue mempresentasikan warna dari merah ke hijau (0-255)

S = Saturation mempresentasikan merah ke merah muda (0-255)

#### 4. HASIL DAN PEMBAHASAN

Pada penelitian ini menggunakan 400 citra daun anggur yang terdiri dari 4 kelas yang berbeda. Data di split menjadi dua yaitu data training dan data testing, pembagian datasets untuk data training sebanyak 80% sedangkan untuk data testing sebanyak 20%. Pembagian ini bertujuan untuk memastikan bahwa model memiliki cukup data untuk belajar selama

proses pelatihan, serta memastikan evaluasi dilakukan pada data yang belum pernah dilihat oleh model.

Pengujian dilakukan menggunakan algoritma *K-Nearest Neighbors* (KNN). Algoritma ini dipilih karena kesederhanaannya dalam implementasi serta efektivitasnya dalam klasifikasi berbasis jarak. Pada penelitian ini, perhitungan dilakukan dengan beberapa nilai K (1, 2, 3, 4, dan 5) untuk menentukan nilai K yang optimal. Pemilihan nilai K sangat penting, karena mempengaruhi jumlah tetangga terdekat yang digunakan untuk mengklasifikasikan data uji. Selain itu, pengujian model dilakukan hanya sekali untuk setiap nilai K yang diuji. Nilai-nilai pada tabel dihitung menggunakan Persamaan 1 untuk mendapatkan nilai Precision, Persamaan 2 untuk mendapatkan nilai Recall dan persamaan 3 untuk mendapatkan nilai F1 Score.

Tabel 1. Klasifikasi dengan K=1

| Class                 | Precision (%) | Recall (%) | F1-Score (%) | Support |
|-----------------------|---------------|------------|--------------|---------|
| Daun Tanpa Penyakit   | 100%          | 73%        | 84%          | 26      |
| Penyakit Jamur Bulu   | 63%           | 67%        | 65%          | 18      |
| Penyakit Jamur Karat  | 62%           | 83%        | 71%          | 18      |
| Penyakit Jamur Tepung | 61%           | 61%        | 61%          | 18      |
| Overall Metrics       |               |            |              |         |
| Accuracy              |               |            | 71%          | 80      |
| Macro Average         | 72%           | 71%        | 70%          | 80      |
| Weighted Average      | 75%           | 71%        | 72%          | 80      |

Pada tabel 1, dengan nilai K=1 menunjukkan hasil terbaik di antara nilai K lainnya, dengan akurasi keseluruhan (accuracy) sebesar 71%. Pada kelas "Daun Tanpa Penyakit", precision sebesar 100% berarti semua prediksi kelas ini benar. Namun, recall hanya 73%, menunjukkan bahwa tidak semua sampel "Daun Tanpa Penyakit" terklasifikasi dengan benar, sehingga ada 27% dari sampel yang tidak terdeteksi sebagai daun sehat. Pada kelas "Penyakit Jamur Bulu", precision sebesar 63% menunjukkan bahwa hanya 63% dari prediksi untuk kelas ini yang benar-benar merupakan penyakit tersebut. Sementara itu, recall sebesar 67% menandakan bahwa 67% dari total sampel "Penyakit Jamur Bulu" terdeteksi dengan benar sebagai penyakit ini, sedangkan sisanya tidak terklasifikasi dengan tepat. Dengan demikian, meskipun model dapat mendeteksi sebagian besar kasus, masih ada ruang untuk perbaikan dalam akurasi prediksi. Selanjutnya, pada kelas "Penyakit Jamur Karat", precision sebesar 62% menunjukkan bahwa hanya 62% dari prediksi untuk penyakit ini yang

akurat. Meskipun precision terbilang rendah, recall yang lebih tinggi, yaitu 83%, menunjukkan bahwa model mampu mendeteksi sebagian besar sampel "Penyakit Jamur Karat". Hal ini berarti, meskipun terdapat beberapa prediksi yang salah, model ini cukup baik dalam menemukan kasus yang ada. Terakhir, pada kelas "Penyakit Jamur Tepung", precision dan recall sama-sama berada di angka 61%. Hal ini menunjukkan bahwa tingkat ketepatan prediksi dan kemampuan model dalam mendeteksi sampel "Penyakit Jamur Tepung" cukup seimbang, meskipun nilainya tidak terlalu tinggi. Secara keseluruhan, nilai akurasi 71% menunjukkan bahwa model dengan K=1 memberikan hasil yang cukup baik. Macro average F1-Score sebesar 70% mengindikasikan adanya keseimbangan antara precision dan recall di semua kelas, sementara weighted average F1-Score sebesar 72% menunjukkan bahwa model lebih baik dalam menangani kelas-kelas dengan dukungan yang lebih besar.

Tabel 2. Klasifikasi dengan K=2

| Class                 | Precision (%) | Recall (%) | F1-Score (%) | Support |
|-----------------------|---------------|------------|--------------|---------|
| Daun Tanpa Penyakit   | 80.0%         | 77.0%      | 78.0%        | 26      |
| Penyakit Jamur Bulu   | 59.0%         | 72.0%      | 65.0%        | 18      |
| Penyakit Jamur Karat  | 55.0%         | 67.0%      | 60.0%        | 18      |
| Penyakit Jamur Tepung | 73.0%         | 44.0%      | 55.0%        | 18      |
| Overall Metrics       |               |            |              |         |
| Accuracy              |               |            | 66.0%        | 80      |
| Macro Avg             | 67.0%         | 65.0%      | 65.0%        | 80      |
| Weighted Avg          | 68.0%         | 66.0%      | 66.0%        | 80      |

Pada tabel 2, dengan nilai  $K=2$ , diperoleh hasil klasifikasi yang menunjukkan akurasi keseluruhan (accuracy) sebesar 66%. Ini menunjukkan bahwa model dengan  $K=2$  kurang efektif dibandingkan model dengan  $K=1$  yang memiliki akurasi 71%. Pada kelas "Daun Tanpa Penyakit", precision sebesar 80.0% menunjukkan bahwa 80% dari prediksi untuk kelas ini adalah benar, yang berarti model cukup akurat dalam mengidentifikasi daun yang sehat. Namun, recall sebesar 77.0% mengindikasikan bahwa 77% dari total sampel "Daun Tanpa Penyakit" terklasifikasi dengan benar, sehingga ada 23% yang tidak terdeteksi sebagai daun sehat. Selanjutnya, untuk kelas "Penyakit Jamur Bulu", precision sebesar 59.0% menunjukkan bahwa hanya 59% dari prediksi untuk kelas ini yang benar. Dengan recall sebesar 72.0%, model mampu mendeteksi 72% dari total sampel "Penyakit Jamur Bulu". Hal ini menunjukkan bahwa meskipun ada ketidakakuratan dalam prediksi, model cukup baik dalam menangkap sebagian besar kasus penyakit ini. Pada kelas "Penyakit Jamur Karat", precision sebesar 55.0% menunjukkan bahwa hanya 55% dari prediksi

yang akurat. Recall yang lebih tinggi, yaitu 67.0%, menandakan bahwa 67% dari sampel "Penyakit Jamur Karat" terdeteksi dengan benar, namun ada juga prediksi yang salah. Terakhir, pada kelas "Penyakit Jamur Tepung", precision sebesar 73.0% menunjukkan bahwa model cukup baik dalam memprediksi kelas ini. Namun, recall yang rendah sebesar 44.0% menunjukkan bahwa hanya 44% dari sampel "Penyakit Jamur Tepung" yang terdeteksi dengan benar, sehingga ada 56% yang tidak terklasifikasi dengan akurat. Secara keseluruhan, nilai akurasi 66% pada model  $K=2$  menunjukkan performa yang lebih rendah dibandingkan model  $K=1$ . Macro average F1-Score sebesar 65.0% menunjukkan keseimbangan yang tidak optimal antara precision dan recall di semua kelas. Sementara itu, weighted average F1-Score sebesar 66.0% menunjukkan bahwa model ini lebih baik dalam menangani kelas-kelas dengan dukungan yang lebih besar, meskipun masih ada potensi perbaikan dalam akurasi prediksi untuk beberapa kelas.

Tabel 3. Klasifikasi dengan  $K=3$ 

| Class                 | Precision (%) | Recall (%) | F1-Score (%) | Support |
|-----------------------|---------------|------------|--------------|---------|
| Daun Tanpa Penyakit   | 78%           | 54%        | 64%          | 26      |
| Penyakit Jamur Bulu   | 50%           | 56%        | 53%          | 18      |
| Penyakit Jamur Karat  | 48%           | 67%        | 56%          | 18      |
| Penyakit Jamur Tepung | 53%           | 50%        | 51%          | 18      |
| Overall Metrics       |               |            |              |         |
| Accuracy              |               |            | 56%          | 80      |
| Macro Avg             | 57%           | 57%        | 56%          | 80      |
| Weighted Avg          | 59%           | 56%        | 57%          | 80      |

Pada Tabel 3, dengan nilai  $K=3$ , model klasifikasi menunjukkan akurasi keseluruhan sebesar 56%. Angka ini menunjukkan penurunan performa yang signifikan dibandingkan dengan model  $K=1$  (71%) dan  $K=2$  (66%). Pada kelas "Daun Tanpa Penyakit", precision tercatat sebesar 78%, yang berarti 78% dari prediksi untuk kelas ini adalah benar. Namun, recall hanya 54%, menunjukkan bahwa tidak semua sampel "Daun Tanpa Penyakit" terklasifikasi dengan tepat, dengan 46% yang tidak terdeteksi oleh model. Kelas "Penyakit Jamur Bulu" menunjukkan precision sebesar 50%. Hal ini menunjukkan bahwa setengah dari prediksi untuk kelas ini adalah akurat. Dengan recall sebesar 56%, model berhasil mendeteksi 56% dari total sampel "Penyakit Jamur Bulu", meskipun kinerjanya masih perlu ditingkatkan. Untuk kelas "Penyakit Jamur Karat", precision yang diperoleh adalah 48%. Ini berarti hanya 48% dari prediksi untuk kelas ini yang benar. Namun, recall

yang lebih tinggi di angka 67% menunjukkan bahwa model dapat mendeteksi 67% dari sampel "Penyakit Jamur Karat," meskipun terdapat banyak prediksi yang salah. Pada kelas "Penyakit Jamur Tepung," model menghasilkan precision sebesar 53%, yang tergolong rendah. Dengan recall di angka 50%, model berhasil mendeteksi setengah dari sampel "Penyakit Jamur Tepung," namun masih ada 50% yang tidak teridentifikasi dengan baik. Secara keseluruhan, nilai akurasi 56% pada model  $K=3$  menunjukkan performa yang lebih rendah dibandingkan dengan model  $K=1$  dan  $K=2$ . Macro average F1-Score sebesar 56% mencerminkan ketidakseimbangan antara precision dan recall di berbagai kelas. Di sisi lain, weighted average F1-Score mencapai 57%, menunjukkan bahwa model ini lebih baik dalam menangani kelas-kelas dengan dukungan yang lebih besar, tetapi tetap memerlukan perbaikan untuk meningkatkan akurasi prediksi secara keseluruhan.

Tabel 4. Klasifikasi dengan  $K=4$ 

| Class                 | Precision (%) | Recall (%) | F1-Score (%) | Support |
|-----------------------|---------------|------------|--------------|---------|
| Daun Tanpa Penyakit   | 82%           | 54%        | 65%          | 26      |
| Penyakit Jamur Bulu   | 54%           | 72%        | 62%          | 18      |
| Penyakit Jamur Karat  | 50%           | 72%        | 59%          | 18      |
| Penyakit Jamur Tepung | 62%           | 44%        | 52%          | 18      |
| Overall Metrics       |               |            |              |         |

| Class        | Precision (%) | Recall (%) | F1-Score (%) | Support |
|--------------|---------------|------------|--------------|---------|
| Accuracy     |               |            | 60%          | 80      |
| Macro Avg    | 62%           | 61%        | 59%          | 80      |
| Weighted Avg | 64%           | 60%        | 60%          | 80      |

Pada Tabel 4, hasil klasifikasi dengan K=4 menunjukkan akurasi keseluruhan sebesar 60%. Angka ini menunjukkan sedikit peningkatan dibandingkan dengan model K=3 yang memiliki akurasi 56%, tetapi masih lebih rendah dibandingkan dengan model K=1 (71%) dan K=2 (66%). Kelas "Daun Tanpa Penyakit" menunjukkan hasil yang baik dengan precision sebesar 82%. Ini berarti 82% dari prediksi untuk kelas ini adalah benar. Namun, recallnya hanya 54%, menunjukkan bahwa hanya 54% dari total sampel "Daun Tanpa Penyakit" yang terklasifikasi dengan tepat oleh model, menyisakan 46% yang tidak terdeteksi. Pada kelas "Penyakit Jamur Bulu," model menghasilkan precision sebesar 54%. Ini menunjukkan bahwa 54% dari prediksi yang dilakukan untuk kelas ini adalah akurat. Dengan recall yang lebih baik di angka 72%, model berhasil mendeteksi 72% dari total sampel "Penyakit Jamur Bulu," menandakan kinerja yang relatif baik dalam mendeteksi penyakit ini. Untuk kelas "Penyakit Jamur Karat," precision yang diperoleh adalah 50%. Hal ini berarti bahwa

hanya 50% dari prediksi untuk kelas ini yang benar. Namun, recall yang setara dengan 72% menunjukkan bahwa model cukup baik dalam mendeteksi sebagian besar kasus penyakit ini meskipun terdapat kesalahan dalam prediksi. Akhirnya, pada kelas "Penyakit Jamur Tepung," model menunjukkan precision sebesar 62%, tetapi recallnya hanya 44%. Ini menunjukkan bahwa meskipun model dapat memberikan prediksi yang tepat, banyak sampel dari kelas ini yang tidak terdeteksi dengan baik. Secara keseluruhan, akurasi model K=4 sebesar 60% menunjukkan adanya perbaikan kecil dibandingkan model K=3, tetapi masih belum mencapai tingkat yang diharapkan. Macro average F1-Score sebesar 59% mencerminkan ketidakseimbangan antara precision dan recall di berbagai kelas. Sementara itu, weighted average F1-Score mencapai 60%, menunjukkan bahwa model ini lebih efektif dalam menangani kelas-kelas dengan dukungan yang lebih besar, meskipun masih ada kebutuhan untuk perbaikan dalam klasifikasi secara keseluruhan.

Tabel 5. Klasifikasi dengan K=5

| Class                 | Precision (%) | Recall (%) | F1-Score (%) | Support |
|-----------------------|---------------|------------|--------------|---------|
| Daun Tanpa Penyakit   | 88%           | 88%        | 88%          | 88%     |
| Penyakit Jamur Bulu   | 48%           | 48%        | 48%          | 48%     |
| Penyakit Jamur Karat  | 50%           | 50%        | 50%          | 50%     |
| Penyakit Jamur Tepung | 53%           | 53%        | 53%          | 53%     |
| Overall Metrics       |               |            |              |         |
| Accuracy              |               |            | 57%          | 80%     |
| Macro Avg             | 60%           | 58%        | 57%          | 80%     |
| Weighted Avg          | 62%           | 62%        | 62%          | 62%     |


Pada Tabel 5, hasil klasifikasi dengan K=5 menunjukkan akurasi keseluruhan sebesar 57%. Angka ini menunjukkan penurunan kinerja dibandingkan dengan model K=4 yang memiliki akurasi 60%, namun masih dalam kisaran yang dapat dipertimbangkan. Kelas "Daun Tanpa Penyakit" menunjukkan hasil yang sangat baik dengan precision, recall, dan F1-Score semuanya mencapai 88%. Ini berarti bahwa model berhasil mengidentifikasi semua sampel dari kelas ini dengan akurasi yang tinggi, tanpa adanya kesalahan prediksi. Namun, pada kelas "Penyakit Jamur Bulu," precision dan recall masing-masing tercatat sebesar 48%. Ini menunjukkan bahwa model memiliki kesulitan dalam mengidentifikasi kelas ini, dengan hampir setengah dari prediksi yang dilakukan tidak akurat. Kinerja yang rendah ini menunjukkan perlunya peningkatan dalam deteksi penyakit ini. Untuk kelas "Penyakit Jamur Karat," model menunjukkan precision dan recall masing-masing sebesar 50%. Hal ini mencerminkan bahwa hanya separuh dari prediksi untuk kelas ini yang benar, menandakan bahwa ada ruang untuk perbaikan dalam klasifikasi penyakit ini. Sementara itu, kelas "Penyakit

Jamur Tepung" memiliki precision dan recall sebesar 53%. Ini menunjukkan bahwa model dapat memberikan prediksi yang cukup baik, tetapi masih jauh dari tingkat akurasi yang diharapkan. Secara keseluruhan, dengan akurasi 57%, model K=5 menunjukkan penurunan performa dibandingkan model K=4. Macro average F1-Score yang mencapai 57% mencerminkan ketidakseimbangan antara precision dan recall di berbagai kelas. Sementara itu, weighted average F1-Score sebesar 62% menunjukkan bahwa model ini lebih efektif dalam menangani kelas-kelas dengan dukungan yang lebih besar, tetapi masih memerlukan peningkatan untuk mencapai akurasi prediksi yang lebih baik secara keseluruhan.

Berdasarkan tabel klasifikasi di atas, hasil pengujian dengan nilai K=1 menunjukkan score tertinggi dengan akurasi sebesar 71%. Nilai ini lebih tinggi dibandingkan pengujian dengan nilai K=2 yang menghasilkan akurasi 66%. Sementara itu, nilai K=3 menghasilkan akurasi 56%, K=4 menghasilkan 60%, dan pengujian dengan nilai K=5 menunjukkan penurunan akurasi menjadi 57%. Dari hasil tersebut, dapat disimpulkan bahwa semakin besar nilai K, maka



semakin rendah akurasi yang diperoleh. Nilai  $K=1$  memberikan hasil terbaik, namun nilai  $K$  yang terlalu kecil dapat menyebabkan model overfitting, sedangkan nilai  $K$  yang terlalu besar menyebabkan model underfitting, yang membuat klasifikasi menjadi kurang spesifik terhadap data uji. Secara keseluruhan,  $K=1$  adalah nilai optimal untuk klasifikasi penyakit daun anggur berdasarkan dataset dan metode yang digunakan dalam penelitian ini. Nilai  $K$  yang tepat memungkinkan model untuk menghasilkan klasifikasi yang lebih akurat, terutama pada citra daun yang sehat atau yang terkena penyakit dengan gejala jelas.



## 5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem deteksi penyakit daun anggur menggunakan metode K-Nearest Neighbors (KNN) dengan teknik ekstraksi fitur berbasis citra digital, termasuk tekstur (Local Binary Pattern/LBP), morfologi (deteksi tepi Canny dan Hu Moments), serta warna (histogram HSV). Dengan teknik ini, sistem mampu mengidentifikasi berbagai penyakit daun anggur berdasarkan perbedaan visual pada citra yang diuji. Data citra dibagi dengan rasio 80% untuk pelatihan dan 20% untuk pengujian, serta nilai  $K$  diuji dalam rentang 1 hingga 5 untuk menemukan nilai optimal. Hasil penelitian menunjukkan bahwa nilai  $K=1$  memberikan akurasi tertinggi sebesar 71%, sedangkan nilai  $K$  yang lebih besar cenderung menurunkan akurasi, menunjukkan bahwa nilai  $K$  yang terlalu besar mengurangi spesifikasi model terhadap pola data. Selain itu, evaluasi precision, recall, dan F1-score menunjukkan performa terbaik pada kelas daun sehat dan beberapa kelas penyakit tertentu, namun beberapa kelas lainnya menampilkan hasil lebih rendah karena kemiripan fitur visual antar kelas. Secara keseluruhan, sistem ini menunjukkan bahwa KNN efektif dalam mengklasifikasikan penyakit daun anggur, terutama dengan  $K=1$ , dan memiliki potensi besar untuk diterapkan dalam deteksi dini penyakit dalam praktik pertanian, sehingga memungkinkan petani mengambil tindakan preventif lebih awal untuk menjaga kualitas dan kuantitas hasil panen anggur.

## DAFTAR PUSTAKA

- [1] Pratiwi, A. O. (2023). Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan Convolutional Neural Network Dan K-Nearest Neighbor. *Jurnal Ilmiah Teknik Informatika dan Komunikasi*, 201-224 .
- [2] Ananta Dwi Prayoga Alwy, M. S. (n.d.). Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM. *Journal of Deep Learning, Computer Vision, and Digital Image Processing*, 1-10.
- [3] Eko Hari Rachmawanto, H. P. (2021). OPTIMASI EKSTRAKSI FITUR PADA KNN DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG. *DINAMIK*, 58-67.
- [4] Begita Wahyuningtyas, I. I. (2022). Identifikasi Penyakit Pada Daun Kopi Menggunakan Metode Local Binary Pattern Dan Random Forest. *e-Proceeding of Engineering*, 2972-2980.
- [5] Meiriyama, S. D. (2022). Klasifikasi Daun Herbal Berdasarkan Fitur Bentuk Dan Tekstur Menggunakan KNN . *Jurnal Teknik Informatika dan Sistem Informasi* , 2573-2584 .
- [6] Fuad Mahrus Fathoni, C. A. (2024). KLASIFIKASI PENYAKIT DAUN ANGGUR MENGGUNAKAN METODE K-NEAREST NEIGHBOR BERDASARKAN GRAY LEVEL CO-OCCURRENCE MATRIX . *Jurnal Ilmiah Informatika dan Komputer* , 8-15.
- [7] Muslih, & Krismawan, A. D. (2024). KLASIFIKASI PENYAKIT DAUN TOMAT BERBASIS ALGORITMA K-NEAREST NEIGHBOR. *Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK)*, 103-107.
- [8] 2. M. R. I. M. 3. M. T. J. 4. Rasna, "Pemanfaatan Citra Drone dan Neural Network untuk Mendeteksi Penyakit pada Daun," *Journal Technology and Information System* , pp. 83-89.
- [9] M. I. P.-A. Kana Saputra S1, "Ekstraksi Fitur Morfologi Daun Sebagai Penciri Pada Tanaman Obat," *Seminar Nasional Aplikasi Teknologi Informasi*, pp. B-13-B-17, 2018.
- [10] R. H. N. S. L. H. H. F. Andrey Firmando, "Klasifikasi Jenis Buah berdasarkan Citra menggunakan Metode Ekstraksi Ciri," *Jurnal Teknologi dan Sains Modern* , vol. 1, pp. 36-48, 2014.
- [11] T. R. A. R. P. Alan Antoni, "Implementasi Algoritma Convolutional Neural Network Untuk Klasifikasi Citra Kemasan Kardus Defect dan No Defect," *Building of Informatics, Technology and Science*, vol. 4, pp. 1941-1950, 2023.
- [12] H. P. Hadi dan E. H. Rachmawanto, "EKSTRAKSI FITUR WARNA DAN GLCM PADA ALGORITMA KNN UNTUK KLASIFIKASI KEMATANGAN RAMBUTAN," *JIP (Jurnal Informatika Polinema)*, pp. 63-68, 2022.
- [13] D. Normawati and S. A. Prayogi, "Implementasi Naive Bayes Classifier Dan Confusion Matrix

- Pada Analisis Sentimen Bebas Text Pada Twitter," *Jurnal Sains Komputer & Informatika (J-SAKTI)*, pp. 697-711, 2021.
- [14] L. Sumaryanti, "Ekstraksi Fitur Morfologi Menggunakan Metode Deteksi Tepi Pada Citra Digital," *MJRICT : Musamus Journal Of Research Information and Communication Technology*, 2019:41-47.
- [15] D. Retniningrum, A. W. Widodo dan M. A. Rahman , "Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binnary Pattern (LBP)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, pp. 2611-2618, 2019