

Deteksi Penyakit Daun Tomat Berbasis Warna Dan Tekstur Dengan Algoritma *K-Nearest Neighbor*

Muhammad Madavi Syah Putra¹, Erna Dwita Sari Cahyani Putri², Soffiana Agustin³

^{1,2,3} Prodi Teknik Informatika, Universitas Muhammadiyah Gresik

e-mail: 1madaviputra1309@gmail.com, 2ercahyaniput@gmail.com ³, soffiana@umg.ac.id

Abstrak

Penelitian klasifikasi penyakit daun tomat ini sangat penting dilakukan mengingat tomat (*Solanum lycopersicum*) merupakan salah satu komoditas hortikultura utama di Indonesia yang memiliki nilai ekonomi dan gizi tinggi. Namun, produktivitas tomat seringkali terancam oleh berbagai penyakit daun yang secara signifikan dapat menurunkan hasil panen dan berdampak negatif pada pendapatan petani serta suplai pangan nasional. Penelitian ini bertujuan untuk mengembangkan sistem deteksi penyakit daun tomat dengan menggunakan ekstraksi fitur tekstur berdasarkan Local Binary Pattern (LBP) Uniform serta fitur ruang warna HSV. Kedua fitur tersebut kemudian digabungkan untuk klasifikasi menggunakan algoritma *K-Nearest Neighbor* (KNN). Dataset berisi 200 citra daun tomat yang mencakup empat kelas penyakit berbeda, yang diambil dalam berbagai kondisi pencahayaan dan latar belakang untuk merefleksikan variasi nyata di lapangan. Hasil evaluasi menunjukkan bahwa fitur tekstur memberikan performa klasifikasi terbaik dengan akurasi maksimum 0,85 pada $K=3$, sedangkan fitur warna secara individual memiliki akurasi lebih rendah dan kurang stabil. Penggabungan kedua fitur ini mampu mempertahankan akurasi yang tinggi sekaligus meningkatkan kestabilan klasifikasi di beberapa kelas penyakit. Penelitian ini menunjukkan potensi signifikan dari penggabungan fitur tekstur dan warna dalam meningkatkan ketepatan deteksi penyakit daun tomat, yang diharapkan dapat mendukung pemantauan dan pengelolaan tanaman secara lebih efektif, serta berkontribusi pada pengembangan pertanian berkelanjutan di masa depan dengan dukungan teknologi terkini.

Kata kunci— *K-Nearest Neighbors* (KNN), Ekstraksi Fitur HSV, Local Binary Pattern (LBP), Klasifikasi Penyakit Daun Tomat, Deteksi Dini Penyakit

1. PENDAHULUAN


Tanaman Tomat (*Solanum lycopersicum*) adalah salah satu komoditas unggulan hortikultura yang memiliki nilai ekonomi penting di Indonesia. Tomat adalah salah satu jenis sayuran buah yang mempunyai prospek yang sangat baik dalam pengembangan agribisnis karena nilai ekonominya yang tinggi dan memiliki nilai gizi tinggi [1]. Di Indonesia, tomat menjadi komoditas unggulan dengan luas panen meningkat dari 4.142 hektar (2011) menjadi 5.837 hektar (2021) di Sumatera Utara [2], serta potensi produksi hingga 50 ton/hektar [3]. Namun, produktivitas tanaman tomat seringkali terancam oleh serangan berbagai penyakit daun yang dapat menurunkan kualitas dan kuantitas hasil panen secara signifikan, seperti *Early Blight* (Bercak Daun), *Late Blight* (Busuk Daun), *Leaf Mold* (Jamur Daun), *Septoria Leaf Spot* (Bercak Daun Sptoria), *Spider Mites Two Spotted Spider Mite* (Kutu Laba-Laba Berbintik Dua), *Target Spot* (Bintik Bercak), *Tomato Mosaic Virus* (Virus Mozaik Tomat), *Tomato Yellow Leaf Curl Virus* (TYLCV) [4]. Deteksi penyakit daun secara manual masih menjadi tantangan karena memerlukan keahlian khusus dan waktu yang cukup lama, sementara variasi gejala penyakit yang kompleks seringkali sulit dikenali secara visual oleh petani atau pengamat awam. Oleh karena itu, dibutuhkan metode deteksi yang cepat, akurat, dan otomatis untuk mendukung upaya pengendalian penyakit secara efektif dan mencegah penyebaran yang lebih luas.

Algoritma K-Nearest Neighbor (KNN) dipilih sebagai metode klasifikasi yang relatif sederhana dan efektif dibandingkan dengan algoritma lainnya [5]. K-NN adalah metode untuk menemukan kelompok objek dalam data latih yang paling mirip dengan data baru atau data uji [5]. Metode KNN juga memiliki keunggulan dalam hal implementasi yang tidak memerlukan proses pelatihan yang rumit dan dapat beradaptasi dengan variasi data yang ada, KNN dipilih berdasarkan studi C. Nyasulu. (2023) dalam “A comparative study of Machine Learning-based classification of Tomato fungal diseases: Application of GLCM texture features” yang membuktikan algoritma ini optimal untuk dataset (3.000 citra) dengan algoritma klasifikasi yang sederhana namun efektif dalam memanfaatkan fitur tekstur GLCM untuk membedakan penyakit jamur dengan akurasi mencapai 88% [6] dan penelitian Safitri E. tentang “Klasifikasi Penyakit Daun Anggur Berbasis Citra Menggunakan Metode K-Nearest Neighbors (KNN)” yang membuktikan didapatkan akurasi 71% dengan model klasifikasi menggunakan metode KNN pada dataset sebanyak 400 citra dan 4 kelas [7], sehingga penggunaan KNN dapat membantu dalam sistem deteksi dini yang dapat mendukung petani dalam mengambil tindakan pencegahan untuk meningkatkan kualitas dan kuantitas hasil panen. Selain fitur warna, penelitian ini menggabungkan ekstraksi fitur tekstur menggunakan metode Local Binary Pattern (LBP) Uniform dan ekstraksi fitur warna dalam ruang warna HSV (Hue, Saturation, Value). Metode LBP melakukan perbandingan antara nilai biner dari piksel pusat dalam suatu citra dengan nilai dari delapan piksel di sekitarnya, serta digunakan sebagai deskriptor yang berfungsi untuk menganalisis tekstur gambar [8].

Penelitian ini bertujuan untuk mengembangkan sistem deteksi penyakit daun tomat berbasis fitur ruang warna HSV dan fitur tekstur LBP Uniform menggunakan algoritma KNN. Selain itu, penelitian ini juga mengukur akurasi dan performa algoritma KNN dalam klasifikasi penyakit berdasarkan data citra daun tomat. Manfaat yang diharapkan dari penelitian ini adalah memberikan solusi praktis dan efisien bagi petani dan praktisi pertanian dalam mendeteksi penyakit secara dini, sehingga dapat meningkatkan produktivitas dan kualitas hasil panen.

2. METODE PENELITIAN

Penelitian klasifikasi penyakit daun tomat ini dirancang untuk mengembangkan sistem yang mampu mengenali dan mengklasifikasikan jenis penyakit pada daun tomat berdasarkan citra digital. Proses penelitian ini melibatkan beberapa tahapan penting yang saling berkesinambungan, dimulai dari pengumpulan data citra daun tomat, preprocessing, ekstraksi fitur, klasifikasi, dan terakhir hasil klasifikasi dievaluasi. Berikut ini adalah flowchart yang terlihat pada Gambar 1.




Gambar 1. Diagram Alur Mode

Flowchart pada gambar 1 menggambarkan proses analisis citra daun tomat yang dimulai dari pengumpulan dataset daun tomat, dilanjutkan dengan tahap pre-processing untuk mempersiapkan data gambar agar fiturnya dapat diekstraksi dengan baik. Setelah itu, fitur diekstraksi dengan dua pendekatan utama yaitu ekstraksi tekstur menggunakan LBP dan ekstraksi fitur warna. Fitur-fitur yang diperoleh kemudian digunakan sebagai input dalam proses klasifikasi untuk mengidentifikasi kondisi daun, seperti penyakit atau keadaan sehat. Terakhir, hasil klasifikasi dievaluasi untuk menilai akurasi dan performa model sebelum penelitian diselesaikan.

2.1 Pengumpulan Data

Pada tahap awal penelitian ini, data citra daun tomat dikumpulkan sebanyak 200 citra yang diperoleh dari sumber daring. Data citra tersebut mencakup empat kelas utama, yaitu Busuk Daun, *Leaf Mold*, Virus Kuning Keriting Daun, dan daun tanpa penyakit. Pengumpulan data dilakukan secara selektif dengan memastikan bahwa setiap citra yang diambil memiliki kualitas yang baik dan representatif untuk masing-masing kelas penyakit. Selanjutnya, data citra tersebut dibagi menjadi dua bagian, yaitu 180 digunakan sebagai data latih dan 20 sebagai data uji.




Gambar 2. Dataset Daun Tomat (a). Penyakit Busuk Daun (b). Penyakit Leaf Mold (c). Penyakit Virus Kuning Keriting Daun (d). Daun Tanpa Penyakit

Gambar 2 menampilkan berbagai kondisi daun tomat yang menjadi objek penelitian, yang mencakup beberapa jenis penyakit serta daun sehat. Daun dengan penyakit busuk menunjukkan kerusakan parah dengan bagian yang menghitam dan mengering, menandakan adanya infeksi yang merusak jaringan daun. Daun dengan penyakit *Leaf Mold* terlihat dengan bercak-bercak yang mengganggu warna hijau normal daun, menandakan pertumbuhan jamur pada permukaan daun. Sementara itu, daun yang terinfeksi Virus Kuning Keriting menunjukkan perubahan warna kuning mencolok dan bentuk daun yang berubah keriting, yang merupakan ciri khas infeksi virus tersebut. Daun sehat yang berwarna hijau segar tanpa adanya kerusakan berfungsi sebagai referensi untuk membandingkan kondisi daun-daun yang sakit. Keempat contoh ini memberikan representasi visual yang jelas dari dataset yang digunakan dalam proses ekstraksi fitur dan klasifikasi kondisi daun tomat.

2.2 Pre-processing

Preprocessing merupakan tahap yang memiliki dampak langsung terhadap hasil klasifikasi, karena melibatkan pemilihan fitur-fitur dengan nilai signifikan dan mengabaikan fitur yang kurang relevan. Dalam penelitian ini, tahap preprocessing diawali dengan pemilihan ruang warna [9]. Tahap preprocessing data merupakan langkah krusial yang dilakukan sebelum data citra daun tomat dapat digunakan dalam model klasifikasi k-Nearest Neighbors (k-NN). Pada proses ini, data citra yang telah dikumpulkan akan diolah dan dipersiapkan agar lebih optimal untuk pelatihan model. Tujuan utama dari preprocessing adalah meningkatkan kualitas data serta mengekstraksi fitur-fitur penting dari citra yang nantinya akan menjadi input bagi algoritma k-NN dalam proses klasifikasi.



Gambar 3. Alur Pre-Processing

Flowchart pada gambar 3 menggambarkan tahapan penting dari penyiapan citra sebelum ekstraksi fitur, yang bertujuan meningkatkan kualitas data citra agar proses ekstraksi fitur dan klasifikasi selanjutnya dapat berjalan dengan akurat. Berikut rincian Langkah-langkah pre-processing :

a. Pengolahan Ukuran Citra (Resizing)

Pada tahap pengolahan ukuran citra, seluruh gambar daun tomat yang telah dikumpulkan diubah ukurannya menjadi 256x256 piksel. Proses resizing ini dilakukan untuk menyamakan dimensi semua citra sehingga dapat diproses secara konsisten oleh algoritma klasifikasi. Dengan ukuran yang seragam, model dapat lebih mudah mengenali pola dan fitur yang relevan tanpa terganggu oleh variasi ukuran gambar. Selain itu, pengubahan ukuran ini juga membantu mempercepat proses komputasi karena data yang diproses menjadi lebih ringan, namun tetap mempertahankan detail penting yang diperlukan untuk analisis penyakit pada daun.

b. Labelisasi Dataset

Setelah citra di-resize, tahap berikutnya adalah labelisasi dataset secara otomatis berdasarkan struktur folder penyimpanan. Setiap folder mewakili satu kelas penyakit, yaitu Busuk Daun, *Leaf Mold*, Virus Kuning Keriting Daun, dan Tanpa Penyakit. Nama file citra dalam folder tersebut juga diberi kode singkatan sesuai kelasnya, seperti "bd" untuk Busuk Daun, "lm" untuk *Leaf Mold*, "vk" untuk Virus Kuning Keriting Daun, dan "tp" untuk Tanpa Penyakit. Dalam sistem labelisasi yang digunakan oleh model, kelas-kelas ini diberi label numerik sebagai berikut: 1 untuk Busuk Daun, 2 untuk Leaf Mold, 3 untuk Virus Kuning Keriting Daun, dan 4 untuk Tanpa Penyakit. Labelisasi yang sistematis ini sangat penting agar model dapat mengenali dan membedakan setiap kelas penyakit dengan tepat selama proses pelatihan dan pengujian.

c. Konversi Ruang Warna HSV

Pada tahap ini, citra yang awalnya berada dalam ruang warna RGB dikonversi ke ruang warna HSV menggunakan fungsi `rgb2hsv`. Konversi ke ruang warna HSV dilakukan karena ruang warna ini memisahkan informasi warna menjadi tiga komponen utama, yaitu Hue (warna), Saturation (kejenuhan warna), dan Value (kecerahan). Fokus utama dalam proses ini adalah pada channel Saturation, karena channel ini memberikan informasi yang lebih jelas mengenai intensitas warna yang membantu dalam segmentasi daun dari latar belakang. Dengan menggunakan ruang warna HSV, proses segmentasi menjadi lebih efektif dan akurat dibandingkan menggunakan ruang warna RGB secara langsung.

d. Segmentasi

Segmentasi dilakukan untuk memisahkan area daun dari latar belakang pada citra. Proses ini dimulai dengan membaca citra dan mengonversinya ke ruang warna HSV. Selanjutnya, channel Saturation digunakan untuk membuat masker daun (*leafMask*) dengan menerapkan threshold nilai Saturation > 0.2 . Masker ini kemudian dibersihkan dari noise kecil menggunakan fungsi `bwareaopen`, yang menghilangkan area-area kecil yang tidak diinginkan. Lubang-lubang pada masker juga diisi menggunakan fungsi `imfill` agar area daun menjadi lebih solid dan utuh. Hasil akhir segmentasi diperoleh dengan mengalikan masker daun dengan citra asli, sehingga hanya bagian daun yang tersisa untuk dianalisis lebih lanjut. Tahap segmentasi ini sangat penting untuk memastikan bahwa fitur yang diekstraksi berasal dari area daun yang relevan, sehingga meningkatkan akurasi klasifikasi penyakit.

e. Median Filtering

Proses median filtering bekerja dengan cara menggantikan setiap piksel pada citra dengan nilai median dari piksel-piksel di sekitarnya dalam sebuah jendela (*window*) yang biasanya berbentuk persegi, misalnya 3x3 atau 5x5 piksel. Nilai median dipilih karena lebih tahan terhadap nilai ekstrem (*outlier*) dibandingkan dengan rata-rata, sehingga efektif menghilangkan noise impulsif seperti salt-and-pepper noise yang sering muncul pada citra hasil pengambilan gambar di lapangan. Dengan menerapkan median filtering pada citra daun tomat, noise yang dapat mengganggu proses ekstraksi fitur warna (ruang HSV) dan tekstur (Local Binary Pattern - LBP) dapat diminimalkan. Hal ini sangat penting karena keberhasilan klasifikasi penyakit sangat bergantung pada kualitas fitur

yang diambil dari citra. Noise yang berlebihan dapat menyebabkan fitur menjadi tidak representatif dan menurunkan akurasi klasifikasi.

2.3 Ekstraksi Fitur

a. Ekstraksi Fitur Tekstur (uLBP (Uniform Local Binary Pattern))

Ekstraksi fitur tekstur dilakukan menggunakan metode Local Binary Pattern Uniform (uLBP). 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 tomat. Fungsi LBP dapat didefinisikan pada persamaan 1 [10]:

$$LBP(x_c, y_c) = \sum_{i=0}^7 S(i_n - i_c) 2^n. \quad (1)$$

$$S(i_n - i_c) = \begin{cases} 1, & i_n - i_c \geq 0 \\ 0, & i_n - i_c < 0 \end{cases} \quad (2)$$

$$uLBP(x_c, y_c) = \sum_{\substack{i=0 \\ \Gamma(LBP(x_c, y_c)) \leq 2^n}} S(i_n - i_c) 2^n, \quad (3)$$

Keterangan :

$uLBP(x_c, y_c)$ = Nilai Local Binary Pattern uniform pada piksel pusat dengan koordinat (x_c, y_c) .

$S(i_n - i_c) 2^n$ = Fungsi threshold biner yang menghasilkan 1 jika $i_n - i_c \geq 0$ dan 0 jika $i_n - i_c < 0$

i_c = Nilai intensitas grayscale dari piksel pusat pada koordinat (x_c, y_c) Ini adalah nilai intensitas piksel yang sedang dianalisis sebagai pusat pola lokal.

i_n = Nilai intensitas grayscale dari piksel tetangga ke-n di sekitar piksel pusat. Biasanya, n berkisar dari 0 sampai 7, mewakili 8 piksel tetangga di sekitar piksel pusat dalam radius tertentu (misalnya radius 1).

2^n = Bobot biner untuk posisi ke-n dalam pola biner 8-bit.

$\Gamma(LBP(x_c, y_c))$ = Jumlah transisi dari 0 ke 1 atau 1 ke 0 dalam pola biner LBP yang dihasilkan, ditambah 1.

$\{i \in [0, 6] : LBP_i \neq LBP_{i+1}\}$ = Set indeks di mana nilai LBP berubah dari 0 ke 1 atau sebaliknya antara bit ke-i dan bit ke-i + 1.

b. Ekstraksi Fitur Warna (Histogram Ruang Warna HSV)

Warna daun merupakan indikator penting dalam menilai kondisi kesehatan daun tomat. Ekstraksi fitur warna dilakukan dengan menggunakan ruang warna HSV (Hue, Saturation, Value), yang memungkinkan pemisahan informasi warna berdasarkan rona, kejenuhan, dan kecerahan [7].

Dalam penelitian ini, fitur warna diperoleh dengan menghitung histogram pada masing-masing saluran H, S, dan V. Metode ini efektif untuk menangkap perubahan warna yang terjadi akibat infeksi penyakit, seperti munculnya bercak warna atau perubahan rona pada daun yang terinfeksi jamur atau virus. Fitur warna ini sangat membantu dalam meningkatkan akurasi klasifikasi berbagai jenis penyakit daun tomat. Persamaan yang digunakan untuk mencari fitur warna yang diperlukan dalam penelitian ini [11]:

1. Mencari nilai RGB

$$r = \frac{R}{255} \quad g = \frac{G}{255} \quad b = \frac{B}{255} \quad (4)$$

2. Mencari nilai *value*

$$V(\text{value}) = \text{nilai max} \quad (5)$$

3. Mencari nilai *saturation*

$$S, \begin{cases} 0, & \text{jika max=min} \\ \frac{\text{max-min}}{v}, & \text{jika max > 0} \end{cases} \quad (6)$$

4. Mencari nilai *hue*

$$H = \begin{cases} 0, & \text{jika } \max = \min \\ 60^0 \left(\frac{G-B}{\max-\min} \bmod 6 \right), & \text{jika } \max = R \\ 60^0 \left(\frac{B-R}{\max-\min} + 2 \right), & \text{jika } \max = G \\ 60^0 \left(\frac{R-G}{\max-\min} + 4 \right), & \text{jika } \max = B \end{cases} \quad (7)$$

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)

2.4 Klasifikasi

Klasifikasi dalam penelitian ini menggunakan K-NN. K-NN adalah suatu metode yang menggunakan algoritma supervised dimana hasil dari query instance yang baru diklasifikasikan berdasarkan mayoritas dari kategori pada K-NN. Klasifikasi merupakan proses mengelompokkan objek ke dalam beberapa kelas berdasarkan kesamaan karakteristik atau ciri-ciri tertentu. Dalam konteks citra, proses ini biasanya dilakukan dengan mengekstraksi fitur dari gambar yang tersedia [12]. Dalam klasifikasi nilai k dapat mempengaruhi hasil klasifikasi secara signifikan. Namun, tidak ada konsensus umum yang telah dicapai mengenai nilai k mana yang dapat memberikan kinerja klasifikasi optimal K-NN bekerja berdasarkan jarak minimum dari data baru ke data training untuk menentukan tetangga k terdekat maka akan didapat nilai mayoritas sebagai hasil prediksi dari data baru. Perhitungan jarak dari metode K-NN dapat menggunakan formula jarak Euclidean, Cityblock, Chebychev dan Minkowski. Adapun algoritma perhitungan metode K-NN adalah sebagai berikut [13]:

1. Tentukan jumlah k (jumlah tetangga terdekat yang hendak dipilih)
2. Hitung jarak antara data yang akan diklasifikasi dengan seluruh data pelatihan
3. Urutkan secara menaik jarak yang telah terbentuk
4. Tentukan jarak terdekat sejumlah dengan k yang telah ditentukan
5. Pasangkan kelas yang bersesuaian
6. Cari jumlah kelas dari tetangga yang terbanyak dan tetapkan kelas tersebut sebagai kelas data yang akan dievaluasi selanjutnya

2.5 Evaluasi

Setelah proses pemodelan selesai, langkah terakhir adalah proses evaluasi yang bertujuan untuk mengukur kinerja dan hasil klasifikasi model. Dalam penelitian ini, digunakan confusion matrix berukuran 4x4 yang merepresentasikan empat kelas penyakit daun tomat yang diklasifikasikan, yaitu Busuk Daun, Leaf Mold, Virus Kuning Keriting Daun, dan Tanpa Penyakit. Confusion matrix ini sangat umum digunakan dalam pembelajaran mesin untuk klasifikasi terawasi, karena mampu memberikan gambaran lengkap mengenai sejauh mana model mengenali dan membedakan setiap kelas secara akurat [14]. Matriks ini menampilkan jumlah prediksi yang benar dan salah untuk setiap kelas, sehingga memungkinkan analisis mendalam terhadap performa model. Berdasarkan confusion matrix tersebut, dihitung metrik evaluasi seperti akurasi, recall, presisi, dan F1-Score untuk masing-masing kelas. Metrik-metrik ini memberikan gambaran yang komprehensif mengenai kemampuan model dalam mengklasifikasikan penyakit daun tomat secara tepat dan konsisten, serta membantu dalam membandingkan efektivitas metode klasifikasi yang digunakan dalam penelitian ini.

$$Accuracy = \frac{(TP1+TP2+\dots+TPn)}{(TP1 + TP2 + \dots + TPn + FP1 + FP2 + \dots + FPn + FN1 + FN2 + \dots + FNn)} \quad (8)$$

Berdasarkan persamaan 8, akurasi dihitung sebagai perbandingan antara jumlah seluruh prediksi yang benar dengan total jumlah data uji. Dalam konteks ini, TP (True Positive) menunjukkan jumlah prediksi yang sesuai dengan kondisi sebenarnya untuk suatu kelas,

sedangkan FP (False Positive) dan FN (False Negative) menunjukkan prediksi yang tidak sesuai dengan kondisi sebenarnya. Dengan menggunakan informasi ini, evaluasi performa model dalam mengidentifikasi kelas penyakit daun tomat dapat diukur secara komprehensif menggunakan metrik-metrik tersebut. Hal ini memberikan gambaran yang jelas mengenai kemampuan model dalam memprediksi dan mengklasifikasikan setiap kelas penyakit secara akurat dan konsisten [14].


3. HASIL DAN PEMBAHASAN

Klasifikasi penyakit daun tomat menggunakan metode K-Nearest Neighbor (K-NN) telah dilakukan dengan menggunakan data citra daun tomat yang terbagi menjadi empat kelas yaitu Penyakit Busuk Daun, Penyakit Leaf Mold, Virus Kuning Keriting Daun, dan daun tanpa penyakit. Data klasifikasi yang digunakan sebanyak 200 citra, terdiri dari 50 citra untuk masing-masing kelas penyakit Busuk Daun, Leaf Mold, Virus Kuning Keriting Daun, serta 50 citra daun tomat yang sehat tanpa penyakit. Proses klasifikasi ini melibatkan tahap preprocessing citra, ekstraksi fitur warna dan tekstur, serta penerapan algoritma K-NN untuk membedakan kelas penyakit berdasarkan karakteristik visual daun yang terinfeksi maupun yang sehat. Diharapkan hasil klasifikasi ini dapat memberikan hasil yang akurat dan andal dalam mendeteksi berbagai penyakit yang menyerang daun tomat. Berikut penjelasan tahapan proses yang telah dilakukan :

1. Preprocessing

a. Konversi Ruang Warna HSV

Pada tahap ini, citra asli dari format RGB diubah ke ruang warna HSV (Hue, Saturation, Value) menggunakan fungsi konversi warna. Di mana kanal Hue dan Saturation secara khusus merepresentasikan rona dan kejenuhan warna. Konversi ini memudahkan deteksi warna spesifik daun untuk proses selanjutnya, dan hasil kanal Hue serta Saturation dapat divisualisasikan untuk memberi gambaran analisis warna.




Gambar 4. Hasil konversi. (a) Citra Asli. (b) Citra Konversi Ruang Warna Hue dan Saturation

Gambar 4 menunjukkan tiga visualisasi yang menjelaskan transformasi citra daun dari format asli RGB ke kanal-kanal dalam ruang warna HSV. Pada citra asli (Busuk Daun) tampak daun dengan warna coklat kehitaman dan kuning yang merefleksikan kondisi fisik daun. Setelah konversi, kanal Hue menampilkan rona warna murni, namun citra ini didominasi oleh area gelap dengan sedikit bercak terang, mengindikasikan bahwa rona warna pada daun relatif seragam dan kurang kontras sehingga detail rona sulit dibedakan. Sebaliknya, kanal Saturation memperlihatkan intensitas kejenuhan warna, di mana bentuk dan tekstur daun terlihat jelas dengan nilai kejenuhan tinggi pada area daun, sementara latar belakang relatif gelap dengan kejenuhan rendah. Hal ini menunjukkan bahwa kanal Saturation sangat efektif menyoroti perbedaan warna yang pekat pada daun dan bermanfaat dalam pemisahan objek daun dari latar belakang pada proses segmentasi.

b. Segmentasi

Segmentasi bertujuan memisahkan objek daun dari latar belakang berdasarkan kanal Saturation. Proses ini menggunakan threshold tertentu (nilai Saturation lebih dari 0.2) untuk memilih area dengan kejenuhan warna yang cukup tinggi yang diasumsikan sebagai daun. Setelah itu, dilakukan operasi morfologi seperti *bwareaopen* untuk menghilangkan noise kecil dan *imfill* untuk mengisi lubang pada objek daun. Hasil segmentasi berupa citra binary mask jelas yang menandai area daun, yang kemudian digunakan untuk memisahkan daun berwarna dari latar asli citra.




Gambar 5. Citra Segmentasi

Gambar 5 ini menunjukkan dua visualisasi penting dalam proses segmentasi citra daun, dimana bagian kiri menampilkan mask segmentasi berupa citra biner yang membedakan objek daun dari latar belakang dengan warna putih sebagai area daun dan hitam sebagai latar belakang. Mask ini berfungsi sebagai filter untuk memisahkan daun secara tepat dari latar belakang yang tidak diinginkan. Sedangkan bagian kanan menunjukkan hasil citra daun yang telah berhasil disegmentasi, dimana hanya area daun yang terlihat dengan detail tekstur dan warna aslinya, sementara latar belakang telah dihilangkan sehingga fokus analisis terpusat pada objek daun saja. Proses segmentasi ini memungkinkan pemisahan yang akurat antara daun dan lingkungan sekitar sehingga memudahkan tahap-tahap selanjutnya seperti ekstraksi fitur dan klasifikasi penyakit pada daun.

c. Median Filtering

Pada tahapan ini, terlihat pada gambar 6 median filtering diterapkan pada masing-masing kanal HSV dari citra daun yang sudah disegmentasi. Filter median berukuran 3x3 dipilih karena efektif mengurangi noise berbintik tanpa merusak tepi daun. Proses ini meningkatkan kualitas citra, sehingga hasil ekstraksi fitur nantinya menjadi lebih akurat dan tahan terhadap gangguan noise.



Gambar 6. Citra Median Filtering

2. Ekstraksi Fitur

Pada tahap ekstraksi fitur, dilakukan pengubahan ruang warna ke grayscale sebagai persiapan ekstraksi fitur LBP (Local Binary Pattern). Transformasi ini bertujuan untuk menghilangkan informasi warna agar fokus pada tekstur permukaan daun. Selain LBP,

penelitian ini juga menggunakan fitur warna HSV, dapat dilihat dalam tabel 1 dan 2 sebagai berikut.

Tabel 1. Hasil Ekstraksi Fitur Warna HSV

Citra	Label	Ekstraksi Fitur Warna						
		Kolom 1	Kolom 2	Kolom 3	Kolom 4	Kolom 5		Kolom 32
bd (1).JPG	1	0.0062091	0.1939032	0.2176168	0.4021402	0.1620979	0	0.008521
bd (2).JPG	1	0.1879439	0.2225533	0.1500433	0.2997748	0.1254807	3.464E-05	0.0047462
bd (3).JPG	1	0.0540521	0.0964745	0.0247221	0.0223815	0.2105398	0.3925541	0.0008046
bd (4).JPG	1	0.0030726	9.037E-05	4.519E-05	0.0003163	0.0003163	0.0021237	0.0008133
bd (5).JPG	1	0.0540521	0.0964745	0.0247221	0.0223815	0.2105398	0.3925541	0.0008046
lm (1).JPG	2	0.0224982	0.0283582	0.0324392	0.2068436	0.5625938	0.0185217	0.0113363
lm (2).JPG	2	0.0094266	0.0060517	0.0086508	0.1291023	0.5619133	0.2374893	0.0104353
lm (3).JPG	2	0.0060274	0.0284097	0.1520085	0.706825	0.0333346	0.0007718	0.0374876
lm (4).JPG	2	0.0039371	0.0231853	0.0562863	0.5238998	0.3742891	0.0009624	0.0214354
lm (5).JPG	2	0.0123821	0.0101339	0.0909701	0.2234824	0.5516258	0.0625482	0.000302
vk (1).JPG	3	0.0018207	0.0007703	0.0125346	0.7766185	0.2063653	0.0016456	0.0031512
vk (2).JPG	3	0.0012881	0	0.0002221	0.0115933	0.8237463	0.160796	0.0414871
vk (3).JPG	3	0.0010971	0	0	0	0	6.453E-05	0.1386532
vk (4).JPG	3	0.0024783	0.0247109	0.0275842	0.4210186	0.5025501	0.0192874	0.176891
vk (5).JPG	3	0.0021736	0.0012621	0.0038915	0.0051886	0.011464	0.0309564	0.0075726
tp (1).JPG	4	0.0043613	0.0001138	0	3.792E-05	0	0	0.0001517
tp (2).JPG	4	0.0103281	0	0	0	0	0	0.0005787
tp (3).JPG	4	0.034586	0.0320098	0.0209642	0.3504331	0.5126075	0.0003864	0.0033169
tp (4).JPG	4	0.0210194	0.031278	0.0426486	0.6567667	0.2244342	0.003013	0.0010761
tp (5).JPG	4	0.0169615	0.00819	0.0130846	0.1322995	0.5432033	0.2349891	0.0259268

Nilai-nilai pada tabel 1 berfungsi sebagai representasi numerik karakteristik warna pada daun yang membantu dalam proses klasifikasi kondisi daun, seperti membedakan antara daun yang sehat dan yang mengalami berbagai jenis penyakit. Penyajian data tabel ini penting untuk menunjukkan hasil konkret dari tahap ekstraksi fitur yang menjadi dasar analisis lebih lanjut dalam proses klasifikasi.

Tabel 2. Hasil Ekstraksi Fitur Tekstur LBP Uniform

Citra	Label	Ekstraksi Fitur Tekstur						
		Kolom 1	Kolom 2	Kolom 3	Kolom 4	Kolom 5		Kolom 10
bd (1).JPG	1	2164.2104	2134.2751	1027.5797	1029.4364	1342.3199	1015.678	6896.3218
bd (2).JPG	1	2117.4241	2099.0491	907.70508	731.06561	842.479	722.04749	6599.3667
bd (3).JPG	1	1829.5757	1983.6326	1013.3513	1072.9827	1530.9594	1050.903	6082.8711
bd (4).JPG	1	1480.8278	1571.1121	757.59204	719.47186	913.73383	767.17993	4888.1011
bd (5).JPG	1	1829.5757	1983.6326	1013.3513	1072.9827	1530.9594	1050.903	6082.8711
lm (1).JPG	2	1874.6871	1888.1864	854.54742	847.76343	1217.9487	1074.8672	5897.0986
lm (2).JPG	2	1866.5389	1852.4421	977.76019	872.88879	1103.3658	803.04236	5867.3252
lm (3).JPG	2	1540.63	1701.9669	1043.4983	1295.6714	1944.0028	1297.5049	4871.3789
lm (4).JPG	2	2130.1147	2226.4609	1226.2349	1312.2126	1915.329	1356.2456	6841.4009

lm (5).JPG	2	1803.6962	2134.1953	1074.0104	1302.6798	1687.8982	1254.3115	6458.5845
vk (1).JPG	3	2014.147	2085.9895	682.87897	603.32813	655.77301	511.35129	7312.5205
vk (2).JPG	3	1951.9111	1885.7595	648.15137	464.98743	370.1951	441.98071	6369.9844
vk (3).JPG	3	2540.4985	2328.3	870.62665	659.69238	657.75763	707.27673	8013.6191
vk (4).JPG	3	2246.6099	2140.3779	805.82013	652.8324	668.23901	684.36212	6909.645
vk (5).JPG	3	1705.8708	1699.7302	797.32178	769.62775	932.935	750.98334	4836.9727
tp (1).JPG	4	926.46655	1421.191	1471.8989	2329.4771	3862.6689	2239.604	3589.7742
tp (2).JPG	4	1010.0222	1302.0613	1271.2026	1754.0007	2676.6262	1697.2858	3476.7163
tp (3).JPG	4	1285.365	1719.4525	1207.9347	2130.9895	3605.7656	2371.7419	4764.4824
tp (4).JPG	4	1159.0796	1778.4106	1199.5804	1931.6849	3362.8647	1767.2572	4044.8159
tp (5).JPG	4	1410.1838	1742.9532	1367.6185	1802.6217	2493.345	1668.7192	5166.2598

Pada tabel 2 setiap baris mewakili sebuah citra lengkap dengan label kondisi daun yang sesuai, dan kolom-kolom fitur memuat nilai numerik yang menggambarkan karakteristik tekstur permukaan daun berdasarkan pola lokal piksel. Nilai-nilai ini sangat penting untuk membedakan tekstur daun sehat dengan yang mengalami berbagai jenis penyakit, karena perubahan tekstur permukaan daun merupakan indikator signifikan dari kerusakan atau infeksi.

3. Klasifikasi

Proses klasifikasi dilakukan menggunakan metode K-Nearest Neighbor. Nilai K yang digunakan adalah 3, 5 dan 7. Proses klasifikasi ini dilakukan pada masing-masing fitur dan fitur gabungan pada k yang berbeda. Hasil Pengenalan disajikan pada table 3.

Tabel 3. Hasil Klasifikasi pada masing-masing Fitur dengan K=3, 5 dan 7

Citra	Label	K = 3			K = 5			K = 7		
		Warna	Tekstur	Warna & Tekstur	Warna	Tekstur	Warna & Tekstur	Warna	Tekstur	Warna & Tekstur
bd (1).JPG	1	1	1	1	1	1	1	1	1	1
bd (2).JPG	1	1	4	4	1	4	4	1	4	4
bd (3).JPG	1	1	1	1	1	3	3	3	3	3
bd (4).JPG	1	3	1	1	3	2	2	1	4	4
bd (5).JPG	1	1	1	1	1	3	3	3	3	3
lm (1).JPG	2	1	2	2	1	2	2	1	2	2
lm (2).JPG	2	2	2	2	2	2	2	2	2	2
lm (3).JPG	2	2	2	2	2	2	2	2	2	2
lm (4).JPG	2	2	1	1	2	1	1	2	1	1
lm (5).JPG	2	2	2	2	2	2	2	2	2	2
tp (1).JPG	3	4	4	4	4	4	4	4	4	4
tp (2).JPG	3	4	4	4	4	4	4	4	4	4
tp (3).JPG	3	4	4	4	4	4	4	4	4	4
tp (4).JPG	3	4	4	4	4	4	4	4	4	4
tp (5).JPG	3	4	2	2	4	4	4	4	4	4
vk (1).JPG	4	4	3	3	4	3	3	4	3	3
vk (2).JPG	4	3	3	3	2	3	3	2	3	3
vk (3).JPG	4	3	3	3	3	3	3	3	3	3
vk (4).JPG	4	2	3	3	2	3	3	2	3	3
vk (5).JPG	4	1	3	3	1	3	3	3	3	3

Hasil klasifikasi pada tabel 3 menunjukkan kondisi daun tomat berdasarkan fitur warna, tekstur, dan gabungan keduanya dengan menggunakan algoritma KNN pada nilai K sebesar 3, 5, dan 7. Setiap baris mewakili sebuah citra daun dengan label kondisi sebenarnya, sementara kolom-kolom menampilkan hasil klasifikasi berdasarkan fitur warna, tekstur, dan kombinasi warna & tekstur di setiap nilai K. Data ini memberikan gambaran perbandingan efektivitas setiap fitur dan pengaruh nilai K terhadap akurasi klasifikasi, yang penting untuk menentukan konfigurasi terbaik dalam mendiagnosis kondisi daun tomat secara otomatis.

4. Evaluasi

Setelah diketahui hasil klasifikasi pada masing-masing fitur yang digunakan dan dikelola dengan k yang berbeda, berikutnya dilakukan evaluasi dengan menghitung jumlah hasil prediksi yang sesuai dengan label. Hasil akurasi ditampilkan pada tabel 4 sebagai berikut.

Tabel 4. Hasil Evaluasi Akurasi

Citra	K = 3			K = 5			K = 7		
	Warna	Tekstur	Warna & Tekstur	Warna	Tekstur	Warna & Tekstur	Warna	Tekstur	Warna & Tekstur
bd (1).JPG	1	1	1	1	1	1	1	1	1
bd (2).JPG	1	0	1	0	0	1	0	0	1
bd (3).JPG	1	1	1	1	0	1	1	1	1
bd (4).JPG	0	0	1	0	0	1	0	0	1
bd (5).JPG	1	1	1	1	0	1	1	1	1
lm (1).JPG	0	0	1	0	0	1	0	0	1
lm (2).JPG	1	1	1	1	1	1	1	1	1
lm (3).JPG	1	1	1	1	1	1	1	1	1
lm (4).JPG	1	0	1	0	0	1	0	0	1
lm (5).JPG	1	1	1	1	1	1	1	1	1
tp (1).JPG	0	1	1	1	1	1	1	1	1
tp (2).JPG	0	1	1	1	1	1	1	1	1
tp (3).JPG	0	1	1	1	1	1	1	1	1
tp (4).JPG	0	1	1	1	1	1	1	1	1
tp (5).JPG	0	0	1	0	1	1	1	1	1
vk (1).JPG	1	0	1	0	0	1	0	0	1
vk (2).JPG	0	1	1	0	0	1	0	0	1
vk (3).JPG	0	1	1	1	1	1	1	1	1
vk (4).JPG	0	0	1	0	0	1	0	0	1
vk (5).JPG	0	0	1	0	0	1	1	1	1
Akurasi	45%	60%	100%	55%	50%	100%	65%	65%	100%

Hasil evaluasi ini menunjukkan bahwa ekstraksi fitur gabungan antara warna dan tekstur memberikan hasil akurasi yang lebih tinggi dibanding ketika menggunakan ekstraksi fitur tekstur ataupun warna. Hal ini menunjukkan bahwa ekstraksi fitur tekstur dan warna saling melengkapi dalam pengenalan penyakit daun tomat ini. Dalam penggunaan nilai k, penelitian ini menunjukkan bahwa nilai k=7 memberikan hasil pengenalan lebih baik dibanding dengan k=5 maupun k=3.

4. KESIMPULAN

1. Klasifikasi menggunakan kombinasi fitur warna dan tekstur menunjukkan performa terbaik dengan akurasi 100% pada semua nilai K (3, 5, dan 7), menegaskan bahwa ekstraksi fitur gabungan ini sangat efektif dalam mengenali kondisi daun tomat dengan sangat baik dan konsisten.
2. Penggunaan fitur tekstur tunggal menghasilkan performa yang lebih baik dibandingkan fitur warna tunggal, dengan akurasi tertinggi mencapai 65% pada K=7, mengindikasikan

kemampuan model dalam mengenali pola tekstur penyakit daun tomat dengan cukup baik.

3. Fitur warna saja memberikan hasil klasifikasi dengan akurasi terendah, berkisar antara 45% pada K=3 hingga 65% pada K=7, menunjukkan fitur warna kurang sensitif dan stabil dalam mendeteksi berbagai kelas penyakit daun tomat.
4. Nilai K=7 memberikan hasil klasifikasi terbaik secara keseluruhan dibandingkan nilai K=3 dan K=5, baik untuk fitur tunggal maupun gabungan, sehingga pengaturan parameter K pada algoritma K-Nearest Neighbor sangat berpengaruh pada performa model.
5. Penurunan performa pada nilai K yang lebih kecil terutama terjadi pada fitur warna dan tekstur tunggal, yang mengindikasikan sensitivitas model terhadap pemilihan parameter K, dan pentingnya optimasi parameter ini untuk mendapatkan hasil klasifikasi yang akurat dan konsisten.

5. SARAN

Berikut terdapat beberapa saran untuk dilakukan pada penelitian selanjutnya:

1. Disarankan untuk menguji nilai K di luar rentang yang telah dilakukan (3, 5, dan 7) guna menemukan nilai K optimal yang lebih tepat dan dapat meningkatkan performa klasifikasi.
2. Perlu eksplorasi penggunaan algoritma mesin pembelajaran lain seperti Support Vector Machine (SVM), Random Forest, atau metode ensemble learning lainnya, yang berpotensi memberikan peningkatan akurasi dibandingkan metode K-Nearest Neighbor.
3. Dalam tahap pre-processing, penerapan teknik peningkatan kualitas citra (image enhancement) seperti histogram equalization, kontras adaptif, atau filtering lanjutan dapat dilakukan untuk memperjelas fitur dan mendukung deteksi yang lebih akurat.
4. Pengembangan dan penambahan fitur ekstraksi lain seperti fitur morfologi, bentuk daun, atau fitur berbasis deep learning (misalnya fitur dari Convolutional Neural Networks/CNN) dapat membantu menangkap karakteristik penyakit dengan lebih komprehensif dan meningkatkan klasifikasi.
5. Perluasan dataset dengan variasi kondisi lingkungan, pencahayaan, serta penerapan augmentasi data (rotasi, flipping, zooming, perubahan pencahayaan) penting untuk membuat model lebih robust dan mampu menggeneralisasi terhadap kondisi nyata.
6. Eksperimen dengan teknik pengurangan dimensi atau seleksi fitur (feature selection) juga dapat membantu mengidentifikasi fitur paling relevan sehingga meningkatkan efisiensi dan akurasi model.

DAFTAR PUSTAKA

- [1] Sara Wales, Stella M.T Tulung, and Rinny Mamarimbing, "Pertumbuhan dan Produksi Tanaman Tomat (*Solanum lycopersicum* L.) Pada Beberapa Jenis Media Tanam," *Applied Agroecotechnology Journal*, vol. 4, pp. 84–93, Jun. 2023.
 - [2] A. L. Horathius Saragih, . L., and T. Supriana, "Analysis of Demand and Supply of Tomato (*Solanum lycopersicum* L.) in North Sumatra Province," *International Journal of Research and Review*, vol. 10, no. 3, pp. 392–396, Mar. 2023, doi: 10.52403/ijrr.20230346.
 - [3] E. Lagiman Wahyurini and Lagiman, *TEKNIK BUDIDAYA DAN PEMULIHAN TANAMAN TOMAT*. Yogyakarta: Lembaga Penelitian dan Pengabdian Kepada Masyarakat Pembangunan Nasional Veteran Yogyakarta University, 2020.
 - [4] S. PALTU N., "KLASIFIKASI PENYAKIT DAUN PADA TANAMAN TOMAT MENGGUNAKAN RESNET-152," UNIVERSITAS MEDAN AREA, Medan, 2024.
 - [5] N. Puspitasari *et al.*, "METODE K-NEAREST NEIGHBOR DAN FITUR WARNA UNTUK KLASIFIKASI DAUN SIRIH BERDASARKAN CITRA DIGITAL," vol. 10, no. 2, 2023.
-

- [6] C. Nyasulu *et al.*, “A comparative study of Machine Learning-based classification of Tomato fungal diseases: Application of GLCM texture features,” *Heliyon*, vol. 9, no. 11, Nov. 2023, doi: 10.1016/j.heliyon.2023.e21697.
 - [7] E. Safitri *et al.*, “KLASIFIKASI PENYAKIT DAUN ANGGUR BERBASIS CITRA MENGGUNAKAN METODE K-NEAREST NEIGHBORS (KNN),” 2024.
 - [8] N. S. Fatimah and S. Agustin, “Klasifikasi Citra Batik Menggunakan Local Binary Pattern (LBP) dan Support Vector Machine (SVM),” *Jurnal Algoritma*, vol. 22, no. 1, pp. 185–196, May 2025, doi: 10.33364/algoritma/v.22-1.2208.
 - [9] G. M. Tsani, Y. Rahmawati, O. D. Sanyoto, and S. Agustin, “PENGKLASIFIKASIAN DAUN SIRIH DENGAN METODE K-NEAREST NEIGHBOR (KNN) BERBASIS FITUR WARNA GUNA MENDUKUNG PEMANFAATAN TANAMAN OBAT,” 2024.
 - [10] M. Hamdi, H. Bouhamed, A. AlGarni, H. Elmannai, and S. Meshoul, “Deep Learning and Uniform LBP Histograms for Position Recognition of Elderly People with Privacy Preservation,” *International Journal of Computers, Communications and Control*, vol. 16, no. 5, pp. 1–15, 2021, doi: 10.15837/ijccc.2021.5.4256.
 - [11] M. Fahmi Wibawa, M. A. Rahman, and A. W. Widodo, “Penerapan Ruang Warna HSV dan Ekstraksi Fitur Tekstur Local Binary Pattern untuk Tingkat Kematangan Sangrai Biji Kopi,” 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>
 - [12] Nurul Mudhofar and Soffiana Agustin, “Klasifikasi Penyakit Daun Apel Menggunakan Ekstraksi Fitur Warna RGB,” *Repeater : Publikasi Teknik Informatika dan Jaringan*, vol. 2, no. 3, pp. 147–156, Jul. 2024, doi: 10.62951/repeater.v2i3.120.
 - [13] S. A. Rosiva Srg, M. Zarlis, and W. Wanayumini, “Identifikasi Citra Daun dengan GLCM (Gray Level Co-Occurence) dan K-NN (K-Nearest Neighbor),” *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 2, pp. 477–488, Mar. 2022, doi: 10.30812/matrik.v21i2.1572.
 - [14] P. S. Siregar, R. G. Hatika, and B. H. Hayadi, “Multiple Choice Question Difficulty Level Classification with Multi Class Confusion Matrix in the Online Question Bank of Education Gallery,” *Journal of Applied Data Sciences*, vol. 4, no. 4, pp. 392–406, Dec. 2023, doi: 10.47738/jads.v4i4.132.
-