

## Implementasi Gray Level Co-Occurrence Matrix (GLCM) Untuk Mendeteksi Penyakit Daun Pada Tanaman Hortikultura

Muhammad Pandawan Juniarta<sup>1</sup>, Muhammad Hafidz Haditya Arrahman<sup>2</sup>, Nani Sulistianingsih<sup>\*3</sup>

<sup>1,2,3</sup>Sistem dan Teknologi Informasi, Universitas Muhammadiyah Mataram, Indonesia

<sup>1</sup>[wanp5933@gmail.com](mailto:wanp5933@gmail.com), <sup>2</sup>[hadityaarrahman555@gmail.com](mailto:hadityaarrahman555@gmail.com), <sup>3</sup>[nani.sulistianingsih@ummat.ac.id](mailto:nani.sulistianingsih@ummat.ac.id)

### ABSTRACT

#### Keywords:

GLCM  
SVM  
KNN  
Leaf Disease  
Horticultural Plant

**Abstract:** Early detection of horticultural plant diseases is crucial for improving agricultural productivity. This study implements the Gray Level Co-Occurrence Matrix (GLCM) as a texture feature extraction method to detect leaf diseases in horticultural plants. The key texture features used include dissimilarity, contrast, energy, correlation, and homogeneity. The classification models applied are Support Vector Machine (SVM) and K-Nearest Neighbor (KNN). The results show that the GLCM method with SVM achieved an accuracy of up to 71% on the corn leaf dataset, while the combination of GLCM and KNN with Euclidean distance achieved 79% accuracy on corn leaves. However, the model's accuracy decreased for the potato and tomato datasets, with the highest values reaching 43% and 30%, respectively, using the GLCM and SVM combination. For the tomato dataset, the combination of GLCM and KNN reached 30%, while for the potato dataset, it achieved an accuracy of 52%. Confusion matrix analysis indicates that the selection of the K parameter in KNN affects classification performance. These findings suggest that while GLCM is effective for texture feature extraction, further optimization is required, particularly in model parameter selection and dataset quality. This study provides valuable insights into the application of GLCM in image-based plant disease detection systems and highlights the potential for developing hybrid methods to enhance accuracy.

#### Kata Kunci:

GLCM  
SVM  
KNN  
Penyakit Daun  
Tanaman Hortikultura

**Abstrak:** Deteksi dini penyakit tanaman hortikultura sangat penting untuk meningkatkan produktivitas pertanian. Penelitian ini mengimplementasikan Gray Level Co-Occurrence Matrix (GLCM) sebagai metode ekstraksi fitur tekstur untuk mendeteksi penyakit daun pada tanaman hortikultura. Fitur tekstur utama yang digunakan meliputi dissimilarity, contrast, energy, correlation, dan homogeneity. Model klasifikasi yang digunakan adalah Support Vector Machine (SVM) dan K-Nearest Neighbor (KNN). Hasil penelitian menunjukkan bahwa metode GLCM dengan SVM mencapai akurasi hingga 71% pada dataset daun jagung, sementara kombinasi GLCM dan KNN dengan jarak Euclidean menghasilkan akurasi 79% pada daun jagung. Namun, akurasi model menurun pada dataset kentang dan tomat, masing-masing dengan nilai tertinggi 43% dan 30% dengan kombinasi GLCM dan SVM. Untuk dataset tomat kombinasi GLCM dan KNN mencapai 30% dan pada dataset kentang mencapai akurasi 52%. Analisis confusion matrix menunjukkan bahwa pemilihan parameter K dalam KNN mempengaruhi performa klasifikasi. Hasil ini mengindikasikan bahwa meskipun GLCM efektif dalam ekstraksi fitur tekstur, optimalisasi lebih lanjut diperlukan, terutama dalam pemilihan parameter model dan kualitas dataset. Kajian ini memberikan wawasan penting mengenai penerapan GLCM dalam sistem deteksi penyakit tanaman berbasis citra serta potensi pengembangan metode hibrida untuk meningkatkan akurasi.

#### Article History:

Received : 25-02-2025

Accepted : 27-03-2025



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license

### A. LATAR BELAKANG

Deteksi dini penyakit tanaman hortikultura sangat penting dalam meningkatkan produktivitas dan kualitas hasil pertanian. Salah satu metode yang banyak digunakan dalam analisis citra untuk identifikasi penyakit tanaman adalah *Gray Level Co-Occurrence Matrix* (GLCM). GLCM merupakan metode ekstraksi fitur tekstur berbasis statistik yang menganalisis hubungan spasial antar piksel dalam suatu citra. Fitur yang dihasilkan, seperti kontras, homogenitas, energi dan korelasi,

memungkinkan karakterisasi pola tekstur yang berbeda antara daun sehat dan daun yang terinfeksi penyakit. Pada beberapa penelitian, kombinasi GLCM dengan algoritma pembelajaran mesin seperti *Support Vector Machine* (SVM) dan *K-Nearest Neighbor* (KNN) telah menunjukkan akurasi tinggi dalam mendeteksi penyakit tanaman hortikultura (Gao, 2021).

Penggunaan GLCM dalam identifikasi penyakit daun tanaman hortikultura terbukti meningkatkan akurasi dan efisiensi sistem deteksi penyakit. GLCM telah diterapkan pada berbagai jenis tanaman dengan hasil yang menjanjikan. Misalnya, pada penyakit daun mentimun, fitur tekstur yang diekstraksi menggunakan GLCM diklasifikasikan dengan SVM, mencapai akurasi sebesar 98,62% (Widodo et al., 2018). Pada penelitian lain, ekstraksi fitur GLCM pada daun cabai merah dikombinasikan dengan klasifikasi SVM, menghasilkan akurasi 98% (Lumbantoran & Sibarani, 2023). Sementara itu, untuk penyakit daun jeruk, GLCM digunakan dengan klasifikasi KNN berbasis jarak Euclidean yang mencapai akurasi 98,84% setelah normalisasi dataset. Keberhasilan metode ini menunjukkan bahwa GLCM efektif dalam menangkap perbedaan tekstur akibat infeksi penyakit tanaman (Pi & Lima, 2021).


Implementasi dan evaluasi model klasifikasi dalam deteksi penyakit daun menggunakan fitur GLCM menunjukkan hasil yang konsisten dalam berbagai penelitian. GLCM mampu mengekstrak fitur tekstur utama seperti kontras, homogenitas, energi, dan korelasi, yang memungkinkan deteksi perubahan permukaan daun akibat penyakit (Widodo et al., 2018). Berbagai algoritma pembelajaran mesin telah digunakan untuk meningkatkan performa klasifikasi, termasuk SVM dan KNN. Sebagai contoh, klasifikasi penyakit daun cabai merah menggunakan SVM menghasilkan akurasi 98%. Model berbasis KNN yang menggunakan jarak Euclidean juga menunjukkan hasil yang kompetitif dalam berbagai skenario klasifikasi. Selain itu, kinerja model dievaluasi menggunakan metrik seperti akurasi, presisi, dan skor F1. Hasil penelitian ini menunjukkan bahwa kombinasi GLCM dengan teknik klasifikasi yang tepat dapat meningkatkan efektivitas sistem deteksi penyakit tanaman.

Validasi model berbasis GLCM menunjukkan keunggulan dalam mendeteksi penyakit daun dengan akurasi tinggi, tetapi beberapa penelitian menyarankan bahwa pemilihan metode klasifikasi yang optimal masih menjadi tantangan (Mukti et al., 2024). Misalnya, GLCM yang diterapkan pada deteksi penyakit daun cabai merah mencapai akurasi 98% dengan klasifikasi SVM. Model berbasis KNN, yang bergantung pada pemilihan parameter optimal seperti jumlah tetangga ( $k$ ), juga menunjukkan kinerja yang kompetitif dalam berbagai dataset penyakit tanaman hortikultura (Nasution et al., 2022). Selain itu, metrik kinerja seperti presisi, ingatan, dan akurasi menunjukkan bahwa pemilihan metode klasifikasi yang tepat sangat mempengaruhi hasil deteksi. Oleh karena itu, penelitian lebih lanjut diperlukan untuk mengeksplorasi kombinasi GLCM dengan teknik optimasi parameter dalam klasifikasi SVM dan KNN guna meningkatkan kinerja sistem (Khastini et al., 2020).

Meskipun metode berbasis GLCM telah menunjukkan efektivitas tinggi dalam ekstraksi fitur tekstur dan deteksi penyakit daun tanaman hortikultura, terdapat beberapa research gap yang perlu diatasi. Salah satu tantangan utama adalah kurangnya eksplorasi terhadap pemilihan parameter optimal dalam klasifikasi SVM dan KNN untuk meningkatkan akurasi deteksi. Selain itu, penelitian sebelumnya jarang membandingkan secara mendalam kelebihan dan kekurangan kedua metode klasifikasi tersebut dalam berbagai kondisi pencahayaan dan jenis penyakit daun. Oleh karena itu, penelitian ini berkontribusi dengan mengevaluasi secara komprehensif performa SVM dan KNN dalam klasifikasi penyakit daun berbasis GLCM, serta mengusulkan strategi optimasi parameter untuk meningkatkan akurasi dan efisiensi sistem. Tujuan utama dari penelitian ini adalah untuk mengimplementasikan GLCM dalam deteksi penyakit daun pada tanaman hortikultura secara lebih efektif, dengan mengevaluasi dan membandingkan performa algoritma SVM dan KNN guna mendapatkan solusi yang optimal.

## B. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif untuk mendeteksi penyakit daun pada tanaman hortikultura dengan metode GLCM dan klasifikasi SVM serta KNN (Fandi, 2020). Alur penelitian dimulai dengan pengumpulan dataset gambar daun dari berbagai jenis tanaman hortikultura. Dataset ini kemudian diproses melalui tahap pra-pemrosesan untuk meningkatkan kualitas citra, seperti konversi ke skala abu-abu dan normalisasi. Selanjutnya, fitur tekstur diekstraksi menggunakan metode GLCM untuk mendapatkan parameter utama seperti kontras, energi, homogenitas, disimilarity dan korelasi. Berikut langkah langkah dalam penelitian ini dapat dilihat lebih jelas pada bagan yang ditujukan pada gambar dibawah ini:




**Gambar 1.** Langkah-langkah Penelitian

Sumber data dalam penelitian ini berasal dari koleksi citra daun tanaman hortikultura yang terdokumentasi dalam basis data publik serta hasil pencitraan langsung dari lapangan. Jenis tanaman hortikultura yang digunakan meliputi jagung, kentang, dan tomat, yang dipilih berdasarkan tingkat kerentanannya terhadap penyakit daun. Setelah ekstraksi fitur dilakukan, data yang diperoleh digunakan sebagai input dalam algoritma klasifikasi SVM dan KNN untuk membandingkan kinerja kedua metode ini dalam mendeteksi penyakit daun (Wicaksono & Adler, 2018).

### 1. Tanaman Hortikultura


Tanaman hortikultura merupakan kelompok tanaman yang dibudidayakan untuk memenuhi kebutuhan pangan, estetika, dan pengobatan. Tanaman hortikultura mencakup berbagai spesies, termasuk buah-buahan, sayuran, tanaman hias, dan tanaman obat, yang memainkan peran penting dalam ketahanan pangan serta peningkatan kualitas hidup. Selain sebagai sumber nutrisi esensial yang melengkapi makanan pokok, tanaman hortikultura juga memiliki manfaat estetika dan pengobatan yang signifikan (Jiang et al., 2022). Namun, tantangan seperti perubahan iklim dan keterbatasan lahan subur menuntut adanya pendekatan inovatif dalam budidayanya. Penyakit daun tanaman hortikultura menimbulkan tantangan signifikan bagi produksi tanaman, mempengaruhi hasil dan kualitas. Strategi manajemen yang efektif sangat penting untuk mengurangi dampak ini, dan kemajuan terbaru dalam teknologi, terutama dalam pemrosesan gambar dan pembelajaran mesin, telah meningkatkan deteksi dan klasifikasi penyakit.



**Gambar 2.** Citra Daun Tanaman Hortikultura, Daun Jagung (a), Daun Kentang (b), Daun Tomat (c)

### 2. Gray Level Co-Occurrence Matrix (GLCM)

*Gray Level Co-Occurrence Matrix (GLCM)* adalah metode statistik yang kuat yang digunakan untuk analisis tekstur di berbagai bidang, termasuk pertanian, pencitraan medis, dan pembelajaran mesin. GLCM menangkap hubungan spasial antara intensitas piksel dalam gambar, memungkinkan ekstraksi fitur yang dapat digunakan untuk tugas klasifikasi. Validasi model berbasis GLCM menunjukkan keunggulan dalam mendeteksi penyakit daun dengan akurasi tinggi, tetapi beberapa penelitian menyarankan bahwa pemilihan metode klasifikasi yang optimal masih menjadi tantangan. Misalnya, GLCM yang diterapkan pada deteksi penyakit daun cabai merah mencapai akurasi 98% dengan klasifikasi SVM (Sulistianingsih et al., 2018).



Gambar 3. Arah GLCM dengan sudut 0°, 45°, 90°, 135°

Berikut lima fitur GLCM meliputi:

a. *Dissimilarity*

Mengukur ketidaksamaan tekstur pada gambar. Jika acak itu akan bernilai tinggi dan kurang berharga jika itu seragam.

$$\sum_{i,j=0}^{N-1} P_{i,j} |i - j| \tag{1}$$

b. *Energy*

Mengukur keseragaman piksel dalam sebuah gambar

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i,j)^2 \tag{2}$$

c. *Contrast*

Mengukur tingkat variasi serta tingkat keabuan antara referensi piksel dan tetangga

$$\sum_{n=0}^{N_g-1} |i - j|^2 * \left\{ \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g} P_{d,\theta}(i,j) \right\} \tag{3}$$

d. *Correlation*

Menggambarkan ketergantungan berdasarkan linier dari tingkat keabuan piksel matriks referensi pada piksel-piksel tetangganya.

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{d,\theta}(i,j) * \frac{(i - \mu_x)(i - \mu_y)}{\sigma_x \sigma_y} \tag{4}$$

Dimana :

$$\mu_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} i * P_{d,\theta}(i, j) \quad (5)$$

$$\mu_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} j * P_{d,\theta}(i, j) \quad (6)$$

$$\sigma_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)^2 * P_{d,\theta}(i, j) \quad (7)$$

$$\sigma_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (j - \mu)^2 * P_{d,\theta}(i, j) \quad (8)$$

e. *Homogeneity*

Mengukur tingkat homogenitas lokal gambar

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \left( \frac{1}{1 + (i - j)^2} \right) * (P_{d,\theta}(i, j)) \quad (9)$$

### 3. Support Vector Machine (SVM)

*Support Vector Machines* (SVM) merupakan salah satu metode pembelajaran mesin terawasi yang banyak digunakan dalam tugas klasifikasi dan regresi. Keunggulan utama dari SVM terletak pada kemampuannya dalam mengidentifikasi *hyperplane* optimal yang memisahkan kelas-kelas dalam ruang dimensi tinggi, sehingga menjadikannya alat yang sangat efektif untuk menangani dataset yang kompleks. Memaksimalkan margin antara titik data dari kelas yang berbeda, SVM dapat mencapai kinerja klasifikasi yang tinggi dan mengurangi kemungkinan kesalahan dalam prediksi (Aryawan et al., 2023; Sulistianingsih et al., 2024). Berikut rumus dasar SVM:

a. Persamaan Hyperplane

$$\omega \cdot x + b = 0 \quad (10)$$

Dimana :

$\omega$  = vektor bobot

$x$  = vektor fitur

$b$  = bias

b. Fungsi Keputusan

$$f(x) = \text{sign}(\omega \cdot x + b) \quad (11)$$

c. Optimalisasi Margin

$$\frac{2}{\|\omega\|} \quad (12)$$

d. Subjek

$$y_i(\omega \cdot x_i + b) \geq 1, \forall_i \quad (13)$$

#### 4. K-Nearest Neighbor (KNN)

*K-Nearest Neighbor* (KNN) telah menunjukkan efektivitas yang signifikan dalam klasifikasi daun tanaman hortikultura, khususnya dalam membedakan berbagai spesies berdasarkan fitur morfologi dan warna. Kinerja algoritma bervariasi tergantung pada metode ekstraksi fitur dan dataset yang digunakan, dengan studi melaporkan tingkat akurasi tinggi. Model berbasis KNN, yang bergantung pada pemilihan parameter optimal seperti jumlah tetangga ( $k$ ), juga menunjukkan kinerja yang kompetitif dalam berbagai dataset penyakit tanaman hortikultura. Selain itu, metrik kinerja seperti presisi, ingatan, dan akurasi menunjukkan bahwa pemilihan metode klasifikasi yang tepat sangat mempengaruhi hasil deteksi (Val et al., 2023). Rumus untuk menghitung Euclidean distance antar dua titik dalam ruang Euclidean  $n$ -dimensi:

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (14)$$

Dimana :

$P = (P_1, P_2, \dots, P_n)$  adalah koordinat dari titik pertama

$q = (q_1, q_2, \dots, q_n)$  adalah koordinat dari titik kedua.

$n$  adalah dimensi (jumlah koordinat) ruang Euclidean.

$d(p, q)$  adalah jarak Euclidean antara dua titik  $p$  dan  $q$ .

#### 5. Evaluasi dan Validasi Model

Model klasifikasi dievaluasi menggunakan metrik akurasi, presisi, recall, dan f1-score. Validasi model dilakukan menggunakan teknik  $k$ -fold cross-validation untuk memastikan keandalan hasil. Perbandingan antara metode SVM dan KNN dilakukan dengan menganalisis performa masing-masing model berdasarkan dataset yang sama. Hasil dari penelitian ini akan memberikan rekomendasi metode klasifikasi terbaik untuk deteksi penyakit daun pada tanaman hortikultura berbasis fitur GLCM (Gunawan & Setiawan, 2022).

**Tabel 1.** Predicted Values

	Actual Values	
	Positive	Negative
Positive	TP	FN
Negatif	FP	TN

**Gambar 4.** Confussion Matrix

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$F1 = Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (18)$$

Keterangan:

TP: *True Positive* (Prediksi positif yang benar)

TN: *True Negative* (Prediksi negatif yang benar)


FP: *False Positive* (Prediksi positif yang salah)

FN: *False Negative* (Prediksi negatif yang salah)

## C. HASIL DAN PEMBAHASAN

### 1. Pre Processing Data

*Preprocessing* data adalah langkah awal dalam mempersiapkan dan meningkatkan data citra sebelum digunakan. Pemrosesan gambar diperlukan pada tahap awal ini untuk memodifikasi atau meningkatkan kualitas gambar, sehingga memudahkan pendeteksian objek dalam fokus dan ekstraksi fitur-fiturnya. Penelitian ini diambil data citra daun tanaman hortikultura (jagung, kentang dan tomat) diperoleh melalui basis data publik <https://www.kaggle.com/datasets>. Sebanyak 209 citra tanaman jagung, beserta citra tanaman kentang dan tomat dikumpulkan masing-masing sebanyak 209 citra tanaman kentang dan 221 citra tanaman tomat. Total data yang digunakan pada penelitian ini adalah 639 citra tanaman hortikultura dataset tersebut akan dibagi menjadi 80% data latih dan 20% data uji. Semua gambar dalam dataset memiliki ukuran yang seragam, yaitu 256x256 piksel. Selanjutnya dataset akan dirubah kedalam citra *grayscale*. Berikut sample dari kedua kelas untuk memahami perbedaan dalam fitur visual antara kategori *corn\_health* (jagung sehat), *corn\_blast* (jagung yang terkena penyakit), sebelum melanjutkan ke fase berikutnya.



Gambar 4. Visualisasi Citra *Corn\_Health* dan *Corn\_Blast*

### 2. Ekstraksi Fitur Gray Level Co-Occurrence Matrix (GLCM)

Metode *Gray-Level Co-Occurrence-Matrix* adalah salah satu metode analisis tekstur pada citra. Tekstur merupakan ciri dari suatu citra yang dapat dikenali secara visual tetapi sulit untuk diidentifikasi dan dikuantifikasi, namun dapat dikenali secara statistik dengan membandingkan kepadatan kelompok piksel pada suatu citra (Lusiana et al., 2019). Ekstraksi citra dengan metode GLCM akan menghasilkan lima ciri statistik yaitu *contrast*, *homogeneity*, *energy*, *correlation*, *dissimilarity*. Ciri statistik tersebut didapatkan dengan menghitung kekuatan hubungan antara dua piksel pada jarak dan pada orientasi sudut tertentu (Ramadhani & Bethaningtyas Dyah, 2018). Pada penelitian ini nilai ciri statistik yang didapatkan merupakan nilai rata-rata dari operasi GLCM dengan jarak 1 piksel pada orientasi sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ .

Tabel 2. Hasil ekstraksi fitur GLCM pada Daun Jagung, Tomat, dan Kentang

Fitur GLCM
contrast_0°
contrast_45°
...
homogeneity_0°
homogeneity_45°
...
energy_0°
energy_45°
...
correlation_0°

<b>Fitur GLCM</b>
correlation_45°
...
dissimilarity_0°
dissimilarity_45°
...

### 3. Klasifikasi Support Vector Machine (SVM)

Support Vector Machine (SVM) memiliki beberapa parameter penting yang mempengaruhi kinerjanya seperti: kernel, C (Regularization Parameter), *Gamma*, *Degree*, untuk menemukan kombinasi terbaik yang menghasilkan akurasi optimal.

**Tabel 3.** Hasil Evaluasi SVM Pada Daun Tanaman Jagung

Metric	Class 0 (corn_health)	Class 1 (corn_blast)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.81	0.62	0.71	0.73	71%
Recall	0.68	0.76	0.72	0.71	
F1-Score	0.74	0.68	0.71	0.72	
Support	25	17	42	42	

Evaluasi kinerja dilakukan dengan mempertimbangkan metrik akurasi, *precision*, *recall*, dan *F1-score*, yang memberikan gambaran mengenai efektivitas dalam klasifikasi biner. Kemudian pada akurasi data pengujian atau testing akurasi menjadi 71%.

**Tabel 4.** Confusion Matrix Data Pada Daun Tanaman Jagung dengan SVM

	Predicted Corn_blast	Predicted Corn_health
Actual Corn_blast	13	4
Actual Corn_health	8	17

Tabel 3 di atas menunjukkan Confusion Matrix untuk evaluasi model klasifikasi jagung sehat (corn\_health) dan jagung penyakit (corn\_blast). Model berhasil mengklasifikasikan 17 jagung sakit dan 13 jagung sehat dengan benar. Namun, ada 4 jagung sehat yang salah terdeteksi sebagai jagung blast. Secara keseluruhan, model memiliki akurasi yang baik karena sebagian besar prediksi benar. Presisi untuk corn\_blast sangat tinggi, dan recall untuk corn\_health juga cukup baik meskipun masih ada sedikit kesalahan. Model ini cukup andal dalam membedakan kedua kelas, tetapi bisa ditingkatkan agar lebih akurat.

**Tabel 5.** Hasil Evaluasi SVM Pada Daun Tanaman Kentang

Metric	Class 0 (potato_health)	Class 1 (potato_diseased)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.56	0.39	0.47	0.49	43%
Recall	0.20	0.76	0.48	0.43	
F1-Score	0.29	0.52	0.41	0.39	
Support	25	17	42	42	

Berdasarkan hasil evaluasi pada daun kentang yang disajikan dalam tabel 5, model menunjukkan performa yang kurang optimal dengan tingkat akurasi keseluruhan sebesar 43%.

**Tabel 6.** Confusion Matrix Data Pada Daun Tanaman Kentang dengan SVM

	Predicted potato_diseased	Predicted potato_health
Actual potato_diseased	11	6
Actual potato_health	14	11



Analisis lebih lanjut pada tabel 5 yang menyajikan *confusion matrix* menunjukkan bahwa model mampu mengklasifikasikan 11 sample dari kelas *potato\_diseased* dengan benar, tetapi juga menghasilkan 6 kesalahan klasifikasi di mana sample *potato\_diseased* diklasifikasikan sebagai *potato\_health*. Sementara itu, untuk *potato\_health*, 11 sample yang diklasifikasikan dengan benar, sedangkan 14 sample lainnya salah diklasifikasikan sebagai *potato\_diseased*.

**Tabel 6.** Hasil Evaluasi SVM Pada Daun Tanaman Tomat

Metric	Class 0 (tomato_health)	Class 1 (tomato_diseased)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.29	0.30	0.30	0.30	30%
Recall	0.27	0.32	0.30	0.30	
F1-Score	0.28	0.31	0.30	0.30	
Support	22	22	44	44	

Hasil klasifikasi SVM pada daun tanaman tomat menunjukkan performa yang rendah dengan akurasi keseluruhan hanya 30%. *Precision* untuk kelas *tomato\_health* dan *tomato\_diseased* masing-masing sebesar 0.29 dan 0.30, sedangkan *recall* bernilai 0.27 dan 0.32. *F1-score* untuk kedua kelas pun relatif seimbang, yaitu 0.28 dan 0.31.

**Tabel 5.** *Confusion Matrix* Data Pada Daun Tanaman Tomat dengan SVM

	Predicted tomato_diseased	Predicted tomato_health
Actual tomato_diseased	7	15
Actual tomato_health	16	6

*Confusion matrix* menunjukkan bahwa model salah mengklasifikasikan 15 dari 22 sampel *tomato\_diseased* sebagai *tomato\_health* dan 16 dari 22 sampel *tomato\_health* sebagai *tomato\_diseased*, menandakan tingkat kesalahan yang tinggi. Secara keseluruhan, model SVM yang digunakan kurang mampu membedakan daun sehat dan sakit pada tanaman tomat, yang kemungkinan disebabkan oleh fitur yang kurang representatif atau parameter model yang belum optimal.

#### 4. Klasifikasi K-Nearest Neighbor (KNN)

Pengujian dengan pendekatan yang kedua adalah dengan KNN, dimana algoritma KNN membandingkan beberapa k parameter. Dari hasil pengujian diperoleh k= 5,7,8, dan 20 yang memiliki nilai k tertinggi yaitu 79%.

**Tabel 6.** Hasil Evaluasi KNN Pada Daun Tanaman Jagung

Metric	Class 0 (corn_health)	Class 1 (corn_blast)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.90	0.68	0.79	0.81	79%
Recall	0.72	0.88	0.80	0.79	
F1-Score	0.80	0.77	0.78	0.79	
Support	25	17	42	42	

Model KNN menunjukkan performa terbaik pada daun jagung dengan akurasi keseluruhan sebesar 79%. *Precision* untuk kelas *corn\_health* mencapai 0.90, sementara untuk *corn\_blast* adalah 0.68. Selain itu, *recall* untuk masing-masing kelas adalah 0.72 dan 0.88, yang menunjukkan bahwa model cukup baik dalam mendeteksi daun yang sakit.

**Tabel 7.** *Confusion Matrix* Data Pada Daun Tanaman Jagung dengan KNN

	Predicted Corn_blast	Predicted Corn_health
Actual Corn_blast	15	2
Actual Corn_health	7	18

Model mampu mengklasifikasikan 15 sampel *corn\_blast* dengan benar, tetapi 2 sampel *corn\_health* salah diklasifikasikan sebagai *corn\_blast*. 18 sampel *corn\_health* diklasifikasikan dengan benar, tetapi 2 sampel *corn\_blast* salah diklasifikasikan sebagai *corn\_health*.

**Tabel 8.** Hasil Evaluasi KNN Pada Daun Tanaman Kentang

Metric	Class 0 (potato_health)	Class 1 (potato_diseased)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.65	0.44	0.54	0.56	52%
Recall	0.44	0.65	0.54	0.52	
F1-Score	0.52	0.52	0.52	0.52	
Support	25	17	42	42	

Hasil klasifikasi pada daun kentang menunjukkan akurasi 52%, lebih baik dibandingkan dengan klasifikasi menggunakan SVM sebelumnya (43%). *Precision* untuk *potato\_health* adalah 0.65, lebih tinggi dibandingkan *potato\_diseased* yang hanya 0.44. Namun, *recall* untuk *potato\_health* lebih rendah (0.44) dibandingkan *potato\_diseased* (0.65), yang menunjukkan kecenderungan model lebih baik dalam mendeteksi daun sakit.

**Tabel 9.** *Confusion Matrix* Data Pada Daun Tanaman Kentang dengan KNN

	Predicted potato_diseased	Predicted potato_health
Actual potato_diseased	11	14
Actual potato_health	6	11

Terdapat 11 sampel *potato\_diseased* diklasifikasikan dengan benar, tetapi 6 sampel salah diklasifikasikan sebagai *potato\_health* dan 11 sampel *potato\_health* diklasifikasikan dengan benar, tetapi 14 sampel salah diklasifikasikan sebagai *potato\_diseased*.

**Tabel 10.** Hasil Evaluasi KNN Pada Daun Tanaman Tomat

Metric	Class 0 (tomato_health)	Class 1 (tomato_diseased)	Macro Avg	Weighted Avg	Overall Accuracy
Precision	0.29	0.30	0.30	0.30	30%
Recall	0.27	0.32	0.30	0.30	
F1-Score	0.28	0.31	0.30	0.30	
Support	22	22	44	44	

Pada daun tomat, akurasi yang dicapai oleh KNN adalah 30%, sama dengan hasil klasifikasi menggunakan SVM sebelumnya. *Precision* dan *recall* untuk kedua kelas hampir setara, menunjukkan bahwa model tidak cukup baik dalam membedakan daun sehat dan sakit.

**Tabel 11.** *Confusion Matrix* Data Pada Daun Tanaman Tomat dengan KNN

	Predicted tomato_diseased	Predicted tomato_health
Actual tomato_diseased	7	15
Actual tomato_health	16	6

Model memiliki tingkat kesalahan yang tinggi, dengan hanya 7 sampel *tomato\_diseased* diklasifikasikan dengan benar, sementara 15 sampel salah diklasifikasikan sebagai *tomato\_health*.

Ada 6 sampel *tomato\_health* diklasifikasikan dengan benar, tetapi 16 sampel salah diklasifikasikan sebagai *tomato\_diseased*.

**Tabel 12.** Perbandingan Hasil Akurasi SVM dan KNN

Tanaman	Model	Akurasi
Jagung	SVM	71%
	KNN	79%
Kentang	SVM	43%
	KNN	52%
Tomat	SVM	30%
	KNN	30%

Secara keseluruhan, KNN lebih baik daripada SVM pada sebagian besar kasus, terutama pada dataset dengan pola yang lebih jelas seperti daun jagung. Namun, untuk dataset dengan perbedaan yang kurang jelas seperti daun tomat, model KNN menunjukkan performa lebih baik dalam mengklasifikasikan daun tanaman jagung, kentang, dan tomat dibandingkan dengan model SVM.

#### D. SIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa metode *Gray Level Co-occurrence Matrix* (GLCM) merupakan teknik ekstraksi fitur tekstur yang efektif dalam mendeteksi penyakit daun pada tanaman hortikultura. Dari 14 fitur GLCM yang tersedia, penelitian ini memilih *dissimilarity*, *contrast*, *energy*, *correlation*, dan *homogeneity* sebagai fitur utama. Hasil klasifikasi menggunakan *Support Vector Machine* (SVM) dan *K-Nearest Neighbor* (KNN) memberikan wawasan penting mengenai efektivitas masing-masing algoritma. Kinerja model KNN menunjukkan bahwa akurasi klasifikasi bergantung pada pemilihan parameter K. Pada dataset jagung, akurasi terbaik sebesar 79% dicapai pada K=5, 7, 8, dan 20, sementara pemilihan K yang kurang optimal mengakibatkan fluktuasi akurasi. Dataset kentang dan tomat menunjukkan hasil akurasi yang lebih rendah, masing-masing dengan akurasi tertinggi 52% dan 30%, yang mengindikasikan adanya tantangan dalam mendeteksi penyakit daun pada tanaman ini. Kesalahan klasifikasi yang cukup tinggi dalam membedakan daun sehat dan sakit, terutama pada dataset dengan kualitas rendah, menunjukkan bahwa model masih perlu dioptimalkan. Faktor seperti ketidakseimbangan data, keberagaman kondisi pencahayaan, serta fitur yang kurang informatif kemungkinan menjadi penyebab utama hasil yang kurang optimal pada beberapa dataset.

#### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam penyusunan paper ini, terutama kepada Ibu Nani Sulistianingsih, S.Kom.,M.Eng atas bimbingan, arahan, dan masukan berharga yang telah diberikan selama proses penelitian dan penulisan. Dukungan tersebut menjadi motivasi bagi penulis hingga penelitian ini dapat diselesaikan dengan baik. Semoga hasil penelitian ini bermanfaat bagi perkembangan ilmu pengetahuan serta menjadi referensi yang berguna bagi para pembaca.

#### REFERENSI

- Fandi, M. (2020). Aplikasi Identifikasi Jenis Buah Kurma Dengan Metode GLCM Berbasis Android. *Jurnal Pengembangan Rekayasa Dan Teknologi*. <https://doi.org/10.26623/jprt.v16i1.2109>
- Gao, S. (2021). Gray level co-occurrence matrix and extreme learning machine for Alzheimer's disease diagnosis. *International Journal of Cognitive Computing in Engineering*. <https://doi.org/10.1016/j.ijcce.2021.08.002>
- Khastini, R. O., Maryani, N., Wahyuni, I., & Pratiwi Tri Lantafi, N. (2020). Studi Cemanan Cendawan Pasca Panen Pada Emping Melinjo di Kabupaten Serang. *Leuit (Journal of Local Food Security)*. <https://doi.org/10.37818/leuit.v1i2.10012>
- Mukti, A. A. S., Octariana, G. B. F., Sukmana, K. D., & Bimantoro, F. (2024). Deteksi Parasit Malaria Menggunakan Metode Gray Level Co-Occurance Matrix (GLCM). *Seminar Nasional Teknologi & Sains*.

<https://doi.org/10.29407/stains.v3i1.4356>

- Nasution, Z. P., Farrasati, R., & Sutarta, E. S. (2022). Analisis Usahatani Tumpang Sari Hortikultura pada Fase Tanaman Kelapa Sawit Belum Menghasilkan (TBM) serta Dampaknya terhadap Kesuburan Tanah di Kecamatan Tandun, Rokan Hulu, Riau. *Jurnal Ekonomi Pertanian Dan Agribisnis*. <https://doi.org/10.21776/ub.jepa.2022.006.02.28>
- Pi, P., & Lima, D. (2021). Gray level co-occurrence matrix and extreme learning machine for Covid-19 diagnosis. *International Journal of Cognitive Computing in Engineering*. <https://doi.org/10.1016/j.ijcce.2021.05.001>
- Wicaksono, T. A., & Adler, J. (2018). Analisis Metode GLCM dan SVM untuk Mendeteksi Cacat Kain. *Jurnal Teknik Komputer Unikom-Komputika*.
- Widodo, R., Widodo, A. W., & Supriyanto, A. (2018). Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) Citra Buah Jeruk Keprok (*Citrus reticulata* Blanco) untuk Klasifikasi Mutu. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*.