

Deteksi Penyakit Daun Cabai Menggunakan Kombinasi GLCM Dan HSV dengan Klasifikasi SVM

Nurmadinah*¹, Farid Wajidi², Nurhikma Arifin³
^{1,2,3}Program Studi Teknik Informatika, Universitas Sulawesi Barat
Email: ¹*nurmadinahxtki1@gmail.com, ²faridwajidi@unsulbar.ac.id,
³nurhikmaarifin@unsulbar.ac.id

Abstrak

Cabai merupakan salah satu komoditas hortikultura bernilai ekonomi tinggi di Indonesia. Namun, tanaman ini sangat rentan terhadap berbagai penyakit daun seperti virus kuning, bercak daun, keriting daun, kekurangan nutrisi dan serangan kutu putih. Deteksi penyakit secara manual seringkali tidak akurat dan menghabiskan waktu sehingga dibutuhkan solusi otomatis yang lebih efisien dan efektif. Penelitian ini bertujuan untuk mendeteksi penyakit daun cabai dengan menggunakan fitur tekstur dan warna pada citra daun. Dengan pendekatan ini, petani dapat dengan mudah mengenali jenis penyakit yang menyerang tanaman cabai sehingga dapat mengambil tindakan pengendalian secara lebih cepat dan tepat. Penelitian ini menggunakan 1.150 citra daun cabai yang terbagi dalam lima kategori penyakit, masing-masing terdiri dari 230 citra (184 data latih dan 46 data uji). Kelima kategori tersebut yaitu virus kuning, bercak daun, keriting daun, kekurangan nutrisi, dan kutu putih. Ekstraksi ciri dilakukan pada fitur warna berbasis ruang warna Hue, Saturation, Value (HSV) dan fitur tekstur yang diperoleh melalui metode Gray Level Co-occurrence Matrix (GLCM). Untuk proses klasifikasi, digunakan algoritma Support Vector Machine (SVM) Kernel RBF. Pengujian parameter C (1,5, dan 10) dan Gamma (0.1, 0.01, 0.001, 0.0001, dan 0.00001) menunjukkan bahwa hasil terbaik diperoleh pada sudut 0° dan 135° , dengan parameter $C=10$ dan $\gamma=0.1$, menghasilkan akurasi sebesar 91,30%. Hasil ini menunjukkan bahwa kombinasi fitur (GLCM dan HSV) dan pengujian parameter kernel RBF pada metode SVM mampu meningkatkan akurasi klasifikasi.

Kata kunci: Daun Cabai, Deteksi Penyakit, GLCM, HSV, Support Vector Machine (SVM)

1. PENDAHULUAN

Pondasi ketahanan pangan nasional adalah sektor pertanian, dan Indonesia sebagai negara agraris memiliki beragam produk hortikultura [1]. Tanaman cabai (*Capsicum annum*) merupakan salah satu komoditas hortikultura unggulan yang memiliki nilai ekonomi tinggi serta tingkat konsumsi yang stabil sepanjang tahun [2]. Permintaan terhadap komoditas ini cukup tinggi baik di pasar domestik maupun internasional, mengingat cabai tidak hanya digunakan dalam kebutuhan rumah tangga sehari-hari, tetapi juga menjadi bahan baku utama dalam industri pengolahan makanan, seperti saus, sambal, makanan instan, dan olahan pangan lainnya [3]. Selain itu, cabai juga memiliki peranan penting dalam mendukung pendapatan petani dan ketahanan ekonomi rumah tangga di wilayah pedesaan. Di beberapa daerah, harga cabai pernah melonjak tajam hingga lebih dari 90% pada waktu tertentu. Kenaikan ini biasanya disebabkan oleh faktor cuaca, seperti curah hujan yang terlalu tinggi, musim kemarau panjang, atau serangan hama dan penyakit yang membuat hasil panen menurun. Akibatnya, pasokan cabai di pasar berkurang dan harga pun naik drastis. Kondisi seperti ini menunjukkan bahwa jika produksi di daerah sentra terganggu, dampaknya bisa langsung terasa pada harga cabai di tingkat daerah maupun nasional [4]. Oleh karena itu, peningkatan produktivitas dan pengendalian penyakit tanaman cabai menjadi aspek krusial dalam mendukung keberlanjutan sektor hortikultura dan ketahanan pangan

nasional secara keseluruhan.

Namun demikian, budidaya cabai di Indonesia menghadapi sejumlah tantangan, khususnya serangan hama dan penyakit yang menyerang daun tanaman. Hasil penelitian Zikra, dkk. pada deteksi penyakit daun cabai menunjukkan bahwa tanaman ini rentan terhadap tiga jenis penyakit utama, yaitu virus kuning, keriting daun, dan bercak daun [5]. Ketiga penyakit ini menunjukkan gejala visual yang serupa, sehingga menyulitkan proses identifikasi dini. Selain itu, gangguan lain seperti kekurangan nutrisi dan serangan kutu putih juga memberikan dampak signifikan terhadap kondisi daun. Dengan demikian, terdapat lima jenis gangguan utama yang menjadi fokus dalam penelitian ini. Jika tidak segera ditangani, serangan penyakit tersebut dapat menurunkan kualitas dan kuantitas panen, bahkan menyebabkan kerugian ekonomi yang besar bagi petani. Metode identifikasi penyakit yang selama ini digunakan masih bersifat tradisional dan mengandalkan pengamatan visual oleh petani atau penyuluh lapangan. Cara ini sangat bergantung pada pengalaman individu, bersifat subjektif, dan tidak efisien dari segi waktu maupun akurasi. Oleh karena itu, diperlukan sistem berbasis teknologi yang dapat mendeteksi penyakit tanaman secara otomatis, cepat, dan tepat guna mendukung pengambilan keputusan yang lebih efektif dalam pengendalian penyakit.

Kemajuan teknologi digital, khususnya di bidang kecerdasan buatan dan pengolahan citra digital, membuka peluang besar dalam pengembangan sistem deteksi penyakit tanaman berbasis citra. Salah satu tahap penting dalam proses ini adalah ekstraksi fitur, yaitu pengambilan informasi penting dari gambar untuk membedakan satu kelas dengan lainnya. Dalam konteks citra daun, fitur warna dan tekstur merupakan dua aspek utama yang dapat digunakan untuk mengidentifikasi kondisi fisiologis dan morfologis daun. Fitur warna mencerminkan perubahan pigmen pada daun, sedangkan fitur tekstur menggambarkan pola permukaan berdasarkan distribusi intensitas piksel.

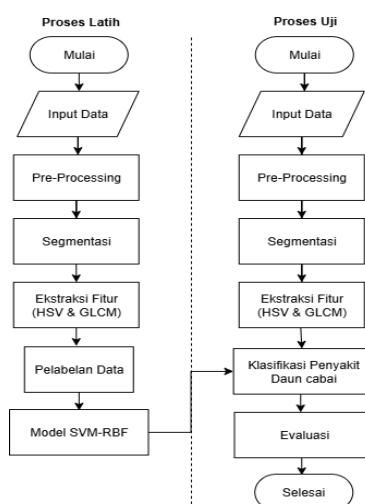
Penelitian ini menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) untuk mengekstraksi fitur tekstur berdasarkan distribusi spasial tingkat keabuan piksel, serta model warna *Hue, Saturation, Value* (HSV) untuk memperoleh informasi rona, kejenuhan, dan kecerahan citra. Kombinasi fitur GLCM dan HSV telah digunakan dalam beberapa penelitian sebelumnya untuk mendeteksi penyakit daun cabai, salah satunya dengan menerapkan algoritma C4.5 berbasis *Raspberry Pi* untuk mengklasifikasikan tiga kategori, yaitu bercak serkospora, mosaik keriting, dan kondisi normal, dengan akurasi mencapai 86% [6]. Penelitian lain yang mengangkat lima jenis penyakit daun cabai serupa telah dilakukan menggunakan pendekatan *image recognition* berbasis algoritma *Support Vector Machine* (SVM) dengan ekstraksi fitur GLCM, dan menghasilkan tingkat akurasi sebesar 82% [7]. Namun, pendekatan tersebut belum mengintegrasikan informasi warna (HSV) yang relevan terhadap gejala visual penyakit daun cabai. Dalam penelitian ini, digunakan algoritma SVM dengan Kernel *Radial Basis Function* (RBF) sebagai metode klasifikasi utama, yang dikenal efektif dalam menangani data *non-linier*. Efektivitas pendekatan ini didukung oleh studi yang dilakukan oleh Adiningsi, dkk. yang berhasil mengklasifikasikan kualitas ikan segar dan tidak segar berdasarkan citra mata ikan. Dataset pada studi tersebut terdiri dari 1.830 citra, yang mencakup 1.050 citra ikan segar dan 870 citra ikan tidak segar, dengan pembagian data pelatihan sebesar 80% dan data pengujian sebesar 20%. Model klasifikasi yang dikembangkan dalam studi tersebut mampu mencapai akurasi sebesar 92,8% dan *F1-score* sebesar 93,4% berdasarkan hasil *confusion matrix* [8]. Dengan menggabungkan fitur GLCM dan HSV serta menggunakan algoritma SVM-RBF, penelitian ini bertujuan untuk mengevaluasi secara lebih menyeluruh performa klasifikasi terhadap lima kelas gangguan utama pada daun cabai yang memiliki kemiripan visual gejala, dan sekaligus menjadi pengembangan lebih lanjut dari studi terdahulu.

Meskipun beberapa penelitian sebelumnya telah memanfaatkan kombinasi fitur tekstur dan warna, sebagian besar hanya mencakup tiga hingga empat kategori penyakit daun cabai. Studi yang dilakukan oleh Nazila dkk. mampu mengklasifikasikan lima kategori penyakit daun cabai menggunakan fitur tekstur berbasis GLCM, namun belum mengintegrasikan informasi warna berbasis HSV dan melakukan pengujian parameter pada algoritma klasifikasi. Keterbatasan tersebut berpengaruh terhadap tingkat akurasi yang diperoleh, yaitu sebesar 82% [7]. Oleh karena itu, penelitian ini berupaya untuk meningkatkan performa klasifikasi dengan menggabungkan

fitur tekstur (GLCM) dan warna (HSV) serta menguji parameter algoritma klasifikasi pada algoritma *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF), guna menghasilkan akurasi yang lebih optimal dalam mendeteksi penyakit daun cabai, sehingga diharapkan, metode yang diusulkan dapat meningkatkan akurasi klasifikasi serta mendukung implementasi pertanian presisi secara praktis dan efisien, sehingga mampu meminimalisasi potensi gagal panen akibat keterlambatan deteksi penyakit.

2. METODE PENELITIAN

Penelitian ini melibatkan proses pengumpulan dataset yang digunakan sebagai data latih (*training data*) dan data uji (*testing data*). Metode yang digunakan dalam penelitian mencakup proses ekstraksi fitur yang terdiri dari fitur warna berbasis model HSV serta fitur tekstur yang diekstraksi menggunakan pendekatan GLCM. Proses klasifikasi dilakukan menggunakan algoritma SVM, yang memerlukan tahapan pelatihan (*training*) dengan menggunakan data latih sebagai masukan utama. Tahapan segmentasi serta ekstraksi fitur dilakukan secara terpisah baik pada citra latih maupun citra uji. Penjabaran metodologi penelitian ini ditunjukkan pada Gambar 1, yang memuat diagram alur proses latih dan uji, mulai dari akuisisi data hingga klasifikasi penyakit daun cabai.



Gambar 1. Diagram Alur Metodologi Penelitian

2.1 Input Data

Dataset yang digunakan dalam penelitian ini diperoleh dari repositori Mendeley dengan tautan <https://data.mendeley.com/datasets/w9mr3vf56s/1> [9], yang terdiri dari 1.150 citra daun cabai dengan lima kategori penyakit, yaitu virus kuning, bercak daun, keriting daun, kekurangan nutrisi, dan kutu putih. Data tersebut melalui tahapan *pre-processing* dan segmentasi, kemudian dibagi menjadi dua subset dengan *rasio* 80:20, yakni 920 citra sebagai data latih (*training*) dan 230 citra sebagai data uji (*testing*). Rincian pengambilan serta distribusi data daun cabai yang terserang penyakit disajikan pada Tabel 1.

2.2 Pre-processing





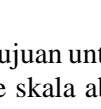
Tahap *pre-processing* dilakukan untuk meningkatkan kualitas citra dan menyederhanakan informasi visual guna mendukung proses segmentasi yang lebih akurat. Pada penelitian ini, tahap awal yang dilakukan adalah menghapus latar belakang citra menggunakan algoritma *Remove Background (Rembg)*, yang menghasilkan citra dalam format *Red, Green, Blue, Alpha* (RGBA). Kanal alpha merepresentasikan tingkat transparansi dari latar belakang yang telah dihilangkan. Kanal alpha dari hasil tersebut digunakan untuk menghasilkan *Mask* objek daun. Untuk memastikan bahwa hanya objek daun utama yang dianalisis, dilakukan seleksi

kontur terbesar dari *Mask* tersebut, sehingga hanya objek daun yang dipertahankan. Selanjutnya, citra dan *Mask* daun diubah menjadi 256×256 piksel untuk menyeragamkan ukuran citra seluruh dataset. Tahapan berikutnya adalah peningkatan kualitas citra, yang dilakukan melalui penyesuaian nilai kontras dan kecerahan menggunakan metode linear *contrast stretching* ($\alpha=1.2$, $\beta=20$), serta diterapkannya filter penajaman (*sharpening*) berbasis kernel konvolusi untuk memperjelas detail tekstur pada permukaan daun. Tahapan ini bertujuan agar informasi penting seperti bercak atau kerusakan daun menjadi lebih mudah dikenali pada tahap segmentasi. Visualisasi hasil citra setelah melalui *pre-processing* ditampilkan pada Gambar 2.



Gambar 2. Penghilangan latar belakang citra untuk menyorot objek daun cabai

Tabel 1. Pengambilan Data Daun Cabai yang Terserang Penyakit

No	Jenis Penyakit	Gambar	Jumlah Citra
1	Virus kuning		230
2	Bercak daun		230
3	Keriting daun		230
4	Kekurangan nutrisi		230
5	Kutu putih		230

2.3 Segmentasi


Segmentasi citra pada penelitian ini bertujuan untuk memisahkan objek daun citra dengan *background*. Proses diawali dengan konversi ke skala abu-abu dan *mean adaptive thresholding* untuk mendeteksi bercak, sedangkan daun keriting diidentifikasi melalui area kuning pucat pada ruang warna HSV dengan rentang *lower_yellow* = [20, 30, 150] dan *upper_yellow* = [40, 150, 255] untuk membentuk *mask* berdasarkan warna kuning pucat. *Mask* yang dihasilkan dari proses *threshold* dan deteksi warna kemudian digabungkan. Untuk mencakup berbagai jenis kerusakan daun, hasil gabungan *mask* diperhalus menggunakan operasi morfologi, yakni *closing* untuk menyatukan area berdekatan dan *opening* untuk menghilangkan bintik kecil *non-target*. Proses dilanjutkan dengan *hole filling* guna menghasilkan *mask* yang lebih maksimal, serta pembersihan objek kecil berukuran < 500 piksel untuk menghindari *noise*.

2.4 Ekstraksi Fitur

a. GLCM (Gray Level Co-occurrence Matrix)

Metode GLCM merupakan teknik ekstraksi citra yang efektif untuk memperoleh informasi tekstur [10]. Dari 14 fitur tekstur yang dapat dihasilkan [11], penelitian ini menggunakan lima parameter utama, yaitu *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation*. Perhitungan GLCM dilakukan dengan jarak antar piksel dan empat orientasi sudut (0° , 45° , 90° , dan 135°) untuk menangkap variasi arah tekstur. Fitur ini merepresentasikan keteraturan intensitas piksel yang berdekatan, sehingga mampu menggambarkan pola permukaan daun yang tidak dapat diwakili hanya oleh fitur warna, dan berguna dalam membedakan gejala penyakit seperti keriting daun, bercak daun, maupun infestasi kutu putih. Ilustrasi relasi piksel antar orientasi tersebut ditampilkan pada Gambar 3. Penjabaran matematisnya dapat dilihat pada

Persamaan (1), (2), (3), (4), dan (5) pada Tabel 2.



Gambar 3. Relasi Pixel Matriks GLCM dari Sudut 0°, 45°, 90°, dan 135°

- Contoh Perhitungan GLCM menggunakan citra 3 bit dengan jarak 1 dan $\theta = 0^\circ$ ([0 1]):

3	5	7
2	4	1
6	3	5

	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0
2	0	0	0	0	1	0	0	0
3	0	0	0	0	0	2	0	0
4	0	1	0	0	0	0	0	0
5	0	0	0	0	0	0	0	1
6	0	0	0	1	0	0	0	0
7	0	0	0	0	0	0	0	0

Setelah Normalisasi →

	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0
2	0	0	0	0	1/6	0	0	0
3	0	0	0	0	0	2/6	0	0
4	0	1/6	0	0	0	0	0	0
5	0	0	0	0	0	0	0	1/6
6	0	0	0	1/6	0	0	0	0
7	0	0	0	0	0	0	0	0

Tabel 2. Parameter dan Contoh Perhitungan fitur GLCM

No	Parameter GLCM	Hitungan
1	<p><i>Contrast</i> menunjukkan perbedaan tingkat warna atau keabuan pada citra, dan bernilai 0 jika piksel bersebelahan memiliki nilai sama [11].</p> $\sum_{i,j} (i - j)^2 \cdot p(i, j) \quad (1)$	<ul style="list-style-type: none"> - $Cont_{(2,4)} = (2-4)^2 \times \frac{1}{6} = \frac{4}{6} = 0,667$ - $Cont_{(3,5)} = (3-5)^2 \times \frac{2}{6} = \frac{8}{6} = 1,333$ - $Cont_{(4,1)} = (4-1)^2 \times \frac{1}{6} = \frac{9}{6} = 1,5$ - $C_{(5,7)} = (5-7)^2 \times \frac{1}{6} = \frac{4}{6} = 0,667$ - $C_{(6,3)} = (6-3)^2 \times \frac{1}{6} = \frac{9}{6} = 1,5$ <p>Jadi, jumlah <i>Contrast</i></p> $= \frac{4+8+9+4+9}{6} = \frac{34}{6} = 5,667$
2	<p><i>Dissimilarity</i> menunjukkan perbedaan intensitas antar piksel bertangga; semakin besar nilainya, semakin besar perbedaan keabuan.[12].</p> $\sum_{i,j} i - j \cdot p(i, j) \quad (2)$	<ul style="list-style-type: none"> - $P(2,4) = \frac{1}{6}$ dengan $(2 - 4 = 2) \rightarrow 2 \cdot \frac{1}{6} = \frac{2}{6} = \frac{1}{3}$ - $P(3,5) = \frac{2}{6}$ dengan $(3 - 5 = 2) \rightarrow 2 \cdot \frac{2}{6} = \frac{4}{6} = \frac{2}{3}$ - $P(4,1) = \frac{1}{6}$ dengan $(4 - 1 = 3) \rightarrow 3 \cdot \frac{1}{6} = \frac{3}{6} = \frac{1}{2}$ - $P(5,7) = \frac{1}{6}$ dengan $(5 - 7 = 2) \rightarrow 2 \cdot \frac{1}{6} = \frac{1}{3}$ - $P(6,3) = \frac{1}{6}$ dengan $(6 - 3 = 3) \rightarrow 3 \cdot \frac{1}{6} = \frac{1}{2}$ <p>Jad, jumlah <i>Dissimilarity</i></p> $= \frac{1}{3} + \frac{2}{3} + \frac{1}{2} + \frac{1}{3} + \frac{1}{2} = 2,333$
3	<p><i>Homogeneity</i> menunjukkan tingkat keseragaman intensitas piksel; nilainya tinggi jika piksel citra seragam[11].</p> $\sum_{i,j} \frac{P(i, j)}{1 + i - j ^2} \quad (3)$	<ul style="list-style-type: none"> - $H_{(2,4)} = \frac{\frac{1}{6}}{1+ 2-4 } = \frac{1}{6 \times (1+ 2-4)} = \frac{1}{18} = 0,050$ - $Hom_{(3,5)} = \frac{\frac{2}{6}}{1+ 3-5 } = \frac{2}{6 \times (1+ 3-5)} = \frac{2}{18} = 0,111$ - $Hom_{(4,1)} = \frac{\frac{1}{6}}{1+ 4-1 } = \frac{1}{6 \times (1+ 4-1)} = \frac{1}{24} = 0,042$ - $Hom_{(5,7)} = \frac{\frac{1}{6}}{1+ 5-7 } = \frac{1}{6 \times (1+ 5-7)} = \frac{1}{18} = 0,056$ - $Hom_{(6,3)} = \frac{\frac{1}{6}}{1+ 6-3 } = \frac{1}{6 \times (1+ 6-3)} = \frac{1}{24} = 0,042$

Jadi, Jumlah *Homogeneity* :

$$= \frac{1+2+1}{18} + \frac{1+1}{24} = \frac{4}{18} + \frac{2}{24} = \frac{2}{9} + \frac{1}{12} = \frac{8+3}{36} = 0,306$$

- 4 *Energy* menunjukkan tingkat keseragaman citra; nilainya tinggi jika intensitas piksel seragam [11].

$$\sum_{i,j} [P(i,j)]^2 \quad (4)$$

$$= \left(\frac{1}{6}\right)^2 + \left(\frac{2}{6}\right)^2 + \left(\frac{1}{6}\right)^2 + \left(\frac{1}{6}\right)^2 + \left(\frac{1}{6}\right)^2$$

$$= \frac{1^2+2^2+1^2+1^2+1^2}{6^2} = \frac{8}{36} = 0,222$$

- 5 *Correlation* menunjukkan hubungan linier antar piksel; nilainya tinggi jika perubahan intensitas keduanya searah.

$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p_{i,j}}{\sigma_i \sigma_j} \quad (5)$$

$$\bullet \mu_i = \sum_i \sum_j i p_{(i,j)}$$

$$= \mu_i = \frac{2+1+3+2+4+1+5+1+6+1}{6} = \frac{23}{6} = 3,833$$

$$\bullet \mu_j = \sum_i \sum_j j p_{(i,j)}$$

$$= \mu_j = \frac{1+1+3+1+4+1+5+2+7+1}{6} = \frac{25}{6} = 4,167$$

$$\bullet \sigma_i = \sqrt{\sum_i \sum_j (i - \mu_i)^2 p_{(i,j)}}$$

$$- \sigma_i (2,4) = \left(2 - \frac{23}{6}\right)^2 x \frac{1}{6} = \frac{121}{36} x \frac{1}{6} = \frac{121}{216} = 0,56$$

$$- \sigma_i (3,5) = \left(3 - \frac{23}{6}\right)^2 x \frac{2}{6} = \frac{25}{36} x \frac{2}{6} = \frac{50}{216} = 0,231$$

$$- \sigma_i (4,1) = \left(4 - \frac{23}{6}\right)^2 x \frac{1}{6} = \frac{1}{36} x \frac{1}{6} = \frac{1}{216} = 0,005$$

$$- \sigma_i (5,7) = \left(5 - \frac{23}{6}\right)^2 x \frac{1}{6} = \frac{49}{36} x \frac{1}{6} = \frac{49}{216} = 0,227$$

$$- \sigma_i (6,3) = \left(6 - \frac{23}{6}\right)^2 x \frac{1}{6} = \frac{169}{36} x \frac{1}{6} = \frac{169}{216} = 0,782$$

$$\sigma_i = \sqrt{\frac{121 + 50 + 1 + 49 + 169}{216}} = \sqrt{\frac{390}{216}} = \sqrt{\frac{65}{36}} = 1,343$$

$$\bullet \sigma_j = \sqrt{\sum_i \sum_j (j - \mu_j)^2 p_{(i,j)}}$$

$$- \sigma_j (4,1) = \left(1 - \frac{25}{6}\right)^2 x \frac{1}{6} = \frac{361}{36} x \frac{1}{6} = \frac{361}{216} = 1,671$$

$$- \sigma_j (6,3) = \left(3 - \frac{25}{6}\right)^2 x \frac{1}{6} = \frac{49}{36} x \frac{1}{6} = \frac{49}{216} = 0,227$$

$$- \sigma_j (2,4) = \left(4 - \frac{25}{6}\right)^2 x \frac{1}{6} = \frac{1}{36} x \frac{1}{6} = \frac{1}{216} = 0,005$$

$$- \sigma_j (3,5) = \left(5 - \frac{25}{6}\right)^2 x \frac{2}{6} = \frac{25}{36} x \frac{2}{6} = \frac{50}{216} = 0,231$$

$$- \sigma_j (5,7) = \left(7 - \frac{25}{6}\right)^2 x \frac{1}{6} = \frac{289}{36} x \frac{1}{6} = \frac{289}{216} = 1,338$$

$$\sigma_j = \sqrt{\frac{361 + 49 + 1 + 50 + 289}{216}} = \sqrt{\frac{750}{216}} = \sqrt{\frac{125}{36}} = 1,863$$

$$- \text{Cor}_{(2,4)} = \frac{\left(2 - \frac{23}{6}\right) x \left(4 - \frac{25}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65}{36} x \frac{125}{36}}} = \frac{\left(-\frac{11}{6}\right) x \left(-\frac{1}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65 x 125}{36}}} = \frac{11}{6 x \sqrt{65 x 125}} = 0,02$$

$$- \text{Cor}_{(3,5)} = \frac{\left(3 - \frac{23}{6}\right) x \left(5 - \frac{25}{6}\right) x \frac{2}{6}}{\sqrt{\frac{65}{36} x \frac{125}{36}}} = \frac{\left(-\frac{5}{6}\right) x \left(-\frac{5}{6}\right) x \frac{2}{6}}{\sqrt{\frac{65 x 125}{36}}} = \frac{-50}{6 x \sqrt{65 x 125}} = 0,093$$

$$- \text{Cor}_{(4,1)} = \frac{\left(4 - \frac{23}{6}\right) x \left(1 - \frac{25}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65}{36} x \frac{125}{36}}} = \frac{\left(\frac{1}{6}\right) x \left(-\frac{19}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65 x 125}{36}}} = \frac{-19}{6 x \sqrt{65 x 125}} = -0,035$$

$$- \text{Cor}_{(5,7)} = \frac{\left(5 - \frac{23}{6}\right) x \left(7 - \frac{25}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65}{36} x \frac{125}{36}}} = \frac{\left(\frac{7}{6}\right) x \left(-\frac{17}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65 x 125}{36}}} = \frac{119}{6 x \sqrt{65 x 125}} = -0,22$$

$$- \text{Cor}_{(6,3)} = \frac{\left(6 - \frac{23}{6}\right) x \left(3 - \frac{25}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65}{36} x \frac{125}{36}}} = \frac{\left(\frac{13}{6}\right) x \left(-\frac{7}{6}\right) x \frac{1}{6}}{\sqrt{\frac{65 x 125}{36}}} = \frac{-91}{6 x \sqrt{65 x 125}} = -0,168$$

Jadi *Correlation* :

$$Corr = \frac{11+(-50)+(-19)+119-91}{6 \times \sqrt{65 \times 125}} = \frac{30}{6 \times \sqrt{65 \times 125}} = -0,056$$

Setelah tahap segmentasi, dilakukan proses ekstraksi fitur untuk memperoleh representasi numerik dari karakteristik visual masing-masing citra. Fitur yang diekstraksi meliputi fitur tekstur menggunakan GLCM dan HSV. Metode GLCM dari empat orientasi sudut (0° , 45° , 90° , dan 135°), Dari setiap *Matriks* GLCM yang dihasilkan, dihitung sejumlah parameter tekstur utama yaitu *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation* pada Tabel 3. Parameter ini merepresentasikan hubungan dan keteraturan antar intensitas piksel yang berdekatan, sehingga mampu menggambarkan informasi dari permukaan daun yang tidak dapat diwakili dari fitur warna. Informasi tekstur ini penting untuk membedakan gejala penyakit dengan pola permukaan berbeda, seperti daun keriting, bercak daun, maupun infeksi kutu putih.

Tabel 3. Rincian hasil ekstraksi fitur tekstur GLCM

<i>class</i>	<i>contrast</i>	<i>dissimilarity</i>	<i>homogeneity</i>	<i>energy</i>	<i>correlation</i>
Bercak daun	251,7824097	3,794583526	0,8278636551	0,5794959068	5699,316895
Daun keriting	41,98450089	2,404835137	0,7144060236	0,2790080607	235,8773651
Kekurangan nutrisi	198,7671814	5,261241989	0,6632686089	0,2257230133	4243,956055
Kutu putih	836,6248779	12,96313664	0,588960237	0,2662996054	12092,8584
Virus kuning	583,3758545	6,10732958	0,8039276402	0,527682662	5248,571289

b. HSV (*Hue*, *Saturation*, *Value*)

HSV merupakan model warna yang mencerminkan persepsi visual manusia, lebih mudah dipahami dibanding RGB [13]. *Hue* mewakili warna dasar, *Saturation* tingkat kejenuhan, dan *Value* kecerahan. Konversi RGB ke HSV dilakukan untuk memperoleh representasi warna yang lebih sesuai dalam pengolahan citra [14]. Transformasi dari ruang warna RGB ke HSV dilakukan berdasarkan persamaan (6), (7), dan (8) yang mendeskripsikan perhitungan masing-masing komponen HSV [13].

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


$$V = \max(r, g, b) \quad (6)$$

$$S = \begin{cases} 0, & \text{Jika Value} \left(1 - \frac{(r, g, b)}{V}\right), V > 0 \\ 0, & \text{Jika } S = 0 \end{cases} \quad (7)$$

$$H = \begin{cases} \frac{60 \cdot (g-b)}{s \cdot v}, & \text{Jika } V = r, 60 \left[2 + \frac{b-r}{s \cdot v}\right], & \text{Jika } V = g, 60 \cdot \left[4 + \frac{r-g}{s \cdot v}\right], & \text{Jika } V = b \end{cases} \quad (8)$$

$$H = H + 360, \text{ Jika } H < 0$$

Pada tahap ekstraksi fitur warna berbasis ruang HSV, citra terlebih dahulu dikonversi dari ruang warna RGB ke HSV yang ditunjukkan pada Gambar 4.



Gambar 4. Konversi RGB Ke HSV

Dari setiap komponen HSV (*Hue, Saturation, dan Value*) dihitung nilai *mean, standard deviation, dan skewness* untuk merepresentasikan karakteristik daun secara lebih menyeluruh. Nilai ini mencerminkan variasi dan distribusi warna pada permukaan daun sehingga dapat digunakan untuk membedakan gejala penyakit seperti bercak daun, keriting daun, kekurangan nutrisi, kutu putih, dan virus kuning. Rincian parameter HSV untuk tiap kelas gejala disajikan pada Tabel 4.

Tabel 4. Hasil ekstraksi fitur warna HSV

<i>class</i>	<i>Hue mean</i>	<i>Hue Std dev</i>	<i>Hue skewness</i>	<i>Saturation mean</i>	<i>Saturation Std dev</i>	<i>Saturation skewness</i>	<i>Value mean</i>	<i>Value std dev</i>	<i>Value skewness</i>
Bercak daun	0,04	0,12	973,10	0,11	0,27	626,48	0,09	0,25	687,63
Daun keriting	0,05	0,10	798,47	0,14	0,30	532,04	0,02	0,06	1766,94
Kekurangan nutrisi	0,10	0,17	415,97	0,26	0,41	269,67	0,11	0,22	487,03
Kutu putih	0,21	0,23	90,33	0,11	0,20	828,50	0,28	0,32	119,71
Virus kuning	0,07	0,14	735,03	0,19	0,35	383,30	0,13	0,30	538,91

Pendekatan kombinasi ini dipilih karena karakteristik penyakit daun cabai tidak hanya bergantung pada pola tekstur, seperti bercak atau keriting, namun juga pada variasi warna yang muncul, misalnya perubahan warna menjadi kuning pada gejala virus.

2.5 Pelabelan Data

Setelah proses ekstraksi fitur selesai, tahap selanjutnya yaitu pelabelan data. Pada tahap ini, setiap data citra daun cabai yang telah diekstraksi diberi label sesuai dengan kategori penyakit. Label tersebut terdiri atas lima kelas, yaitu virus kuning, bercak daun, keriting daun, kekurangan nutrisi, dan serangan kutu putih. Proses pelabelan ini bertujuan agar model klasifikasi SVM-RBF dapat mengenali pola fitur yang khas dari masing-masing penyakit, serta memudahkan evaluasi kinerja model pada tahap pengujian.

2.6 SVM (Support Vector Machine)

Support Vector Machine (SVM) merupakan metode klasifikasi dalam pembelajaran mesin yang banyak digunakan di berbagai bidang, termasuk pengolahan citra digital. SVM bekerja dengan mencari *hyperplane* optimal yang memisahkan data dari kelas berbeda dengan margin maksimum, sehingga meningkatkan kemampuan generalisasi model [15]. Dari penelitian sebelumnya Margarita, dkk., telah menggunakan empat jenis kernel yaitu *polynomial*, RBF (*Radial Basis Function*), *sigmoid*, dan *linear* untuk klasifikasi penyakit daun padi. Akurasi tertinggi diperoleh menggunakan kernel RBF dengan akurasi 93,94% [16].

$$K = (x_i, x_j) = \exp(-\gamma * ||x_i - x_j||^2) \quad (9)$$

Pada rumus (9) menyatakan fungsi kernel RBF, di mana x_i dan x_j adalah vektor fitur, $||x_i - x_j||^2$ menunjukkan jarak *Euclidean* kuadrat antar kedua vektor, sedangkan parameter *gamma* (γ) berfungsi untuk menentukan seberapa besar pengaruh suatu data terhadap data lainnya, semakin tinggi nilainya, semakin ketat rentang pengaruhnya. Dua parameter utama yang mempengaruhi kinerja SVM-RBF adalah *C* (*Cost*), yang mengatur toleransi kesalahan pada saat klasifikasi, dan *gamma* (γ) yang menentukan sensitivitas model. Nilai *C* kecil menghasilkan *margin* lebih lebar (cenderung *underfitting*), sedangkan *C* besar memperkecil kesalahan pelatihan (berisiko *overfitting*). *Gamma* kecil membuat model lebih general, sedangkan *gamma* besar lebih sensitif terhadap data.

Fitur hasil ekstraksi kemudian digunakan sebagai *input* pada proses klasifikasi menggunakan algoritma SVM (*Support Vector Machine*) dengan Kernel RBF (*Radial Basis Function*). Kernel RBF dipilih karena kemampuannya dalam memetakan data *non-linear* ke ruang

berdimensi lebih tinggi sehingga dapat dipisahkan oleh *hyperplane*. Dalam penelitian ini dilakukan pencarian kombinasi parameter terbaik dengan cara mencoba semua nilai C (1, 5, dan 10) dan *gamma* (0.1, 0.01, 0.001, dan 0.0001). Proses ini dikenal sebagai *Grid Search*, yaitu metode yang secara sistematis menguji setiap kombinasi nilai parameter untuk menemukan konfigurasi yang memberikan hasil klasifikasi paling baik.

2.7 Evaluasi

Dalam penelitian ini, kinerja model SVM dengan kernel RBF dievaluasi menggunakan sejumlah metrik standar, yaitu akurasi, presisi, *recall*, dan *F1-Score*. Keempat metrik tersebut dipilih karena mampu memberikan gambaran menyeluruh mengenai kemampuan model dalam melakukan klasifikasi terhadap lima kelas penyakit daun cabai, yaitu virus kuning, bercak daun, keriting daun, kekurangan nutrisi, serta kutu putih. Rumus perhitungan masing-masing metrik ditunjukkan pada persamaan (10), dengan akurasi mengukur ketepatan keseluruhan prediksi, presisi menilai ketepatan klasifikasi positif (11), *recall* menilai kemampuan model dalam mendeteksi kelas positif (12), dan *F1-Score* digunakan untuk menyeimbangkan antara *presisi* dan *recall* (13) [17].

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (11)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (12)$$

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (13)$$

TP (*True Positives*) merupakan prediksi yang benar ketika data diklasifikasikan ke dalam kelas positif, sedangkan TN (*True Negatives*) adalah prediksi yang benar ketika data termasuk dalam kelas negatif. Sementara itu, FP (*False Positives*) menunjukkan kesalahan prediksi ketika data seharusnya negatif namun diklasifikasikan sebagai positif, dan FN (*False Negatives*) terjadi apabila data seharusnya positif tetapi diprediksi sebagai negatif.

3. HASIL DAN PEMBAHASAN

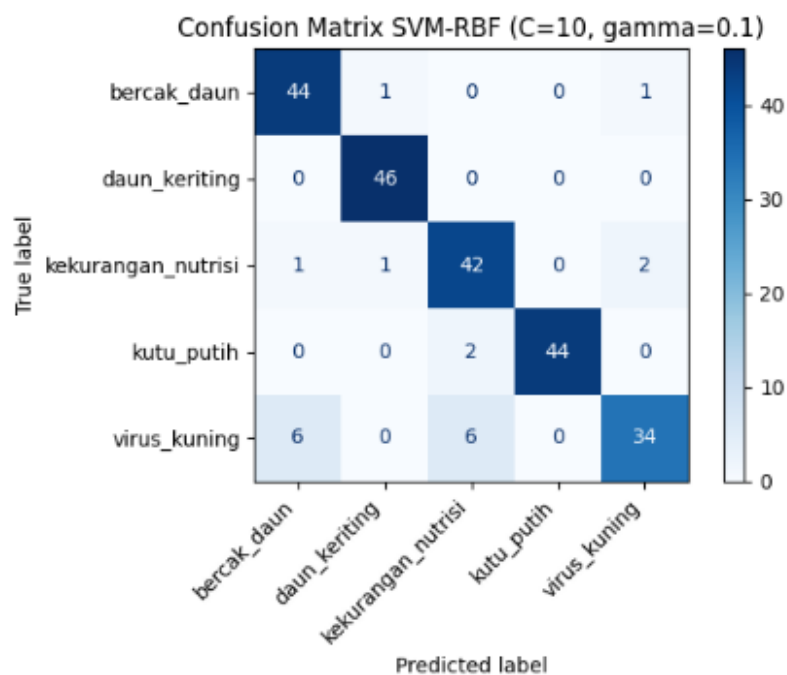
Hasil pengujian deteksi penyakit daun cabai menggunakan kombinasi GLCM dan HSV pada metode klasifikasi SVM dianalisis berdasarkan tingkat akurasi pada data uji, serta dilakukan evaluasi terhadap kontribusi masing-masing parameter terhadap performa model. Pada tahap pengujian ini, digunakan sudut (0°, 45°, 90°, dan 135°) pada ekstraksi fitur GLCM dan untuk metode SVM juga dilakukan pengujian parameter pada kernel RBF yaitu nilai parameter C (1, 5, dan 10) serta *gamma* ($\gamma = 0.1, 0.01, 0.001, \text{ dan } 0.0001$). Pengujian ini dilakukan untuk memperoleh hasil yang lebih optimal. Berikut hasil akurasi pengujian yang dilakukan, ditunjukkan pada Tabel 4.

Tabel 5. Hasil Akurasi Klasifikasi menggunakan fitur HSV dan GLCM dengan Metode SVM-RBF pada sudut GLCM (0°, 45°, 90°, dan 135°).

Angle	C/G	0.1	0.01	0.001	0.0001	0.00001
0°	1	83.04%	73.48 %	69.13%	53.91%	49.13%
	5	90.00%	84.78%	71.30%	64.78%	49.13%
	10	91.30 %	85.65%	73.91%	69.57%	54.35%
45°	1	83.04%	75.22 %	69.13%	50.43%	48.26%
	5	90.00%	82.17%	73.04%	64.78%	48.26%
	10	89.57%	83.91%	74.78%	69.57%	50.43%

90°	1	83.48%	76.09 %	70.00%	50.43%	49.13%
	5	89.13%	82.17%	72.17%	67.39%	49.13%
	10	90.87%	85.65%	74.78%	69.70%	50.43%
135°	1	84.48%	73.91 %	70.43%	49.57%	47.83%
	5	90.87%	84.35%	71.74%	66.96%	47.83%
	10	91.30%	84.78%	75.22%	69.57%	50.00%

Pada Tabel 5, hasil yang diperoleh menunjukkan bahwa penggunaan parameter C dan γ pada metode SVM dengan kernel RBF memiliki pengaruh signifikan terhadap hasil akurasi. Adapun hasil akurasi tertinggi diperoleh dari nilai $C=10$, dan $\gamma=0.1$ pada sudut 0° dan 135° sebesar 91.30% pada rasio data latih dan uji 80:20. Pengujian nilai γ penting dilakukan karena nilai γ yang terlalu besar menyebabkan model menjadi terlalu kompleks (*overfitting*), sehingga akurasi cenderung menurun, sedangkan nilai γ yang terlalu kecil membuat model menjadi terlalu sederhana (*underfitting*) dan juga menghasilkan akurasi rendah. Pada penelitian ini, penggunaan nilai γ 0.1 menghasilkan akurasi yang paling tinggi sedangkan penggunaan γ 0.01, 0.001, dan 0.0001 menghasilkan akurasi yang lebih rendah. Dengan demikian, pemilihan nilai γ yang tepat sangat berpengaruh terhadap model SVM-RBF pada klasifikasi penyakit daun cabai.



Gambar 5. Matriks pada Deteksi Penyakit Daun Cabai

Berdasarkan hasil *confusion matrix* pada Gambar 5 klasifikasi penyakit daun cabai menggunakan SVM dengan fitur GLCM + HSV, berikut adalah analisis dan identifikasi terhadap kesalahan klasifikasi pada Table 5.

Tabel 6. Hasil Akurasi Per Kelas

<i>True \ Pred</i>	Bercak daun	Daun keriting	Kekurangan nutrisi	Kutu putih	Virus kuning	Total Data	Akurasi Per Kelas
Bercak daun	44	1	0	0	1	46	95.65%
Daun keriting	0	46	0	0	0	46	100.00%
Kekurangan nutrisi	1	1	42	0	2	46	91.30%
Kutu putih	0	0	2	44	0	46	95.65%
Virus kuning	6	0	6	0	34	46	73.91%
Total	51	48	50	44	37	230	91.30%

Berdasarkan Tabel 6, hasil analisis menunjukkan bahwa kelas virus kuning mengalami jumlah kesalahan klasifikasi paling banyak, yaitu sebanyak 12 kasus. Hal ini terutama disebabkan oleh kemiripan gejala dengan kelas bercak daun dan kekurangan nutrisi. Perubahan warna daun menjadi kuning yang sering disertai bercak ringan membuat fitur warna dan tekstur antara ketiga kelas tersebut saling tumpang tindih, sehingga model kesulitan membedakannya secara tepat. Selain itu, beberapa citra pada kelas virus kuning menampilkan lebih dari satu jenis gejala sekaligus, sehingga model cenderung salah mengklasifikasikan sebagai penyakit lain. Sebaliknya, kelas daun keriting justru dapat dikenali dengan sempurna tanpa kesalahan. Namun, hal ini belum sepenuhnya mencerminkan kemampuan model yang ideal. Akurasi tinggi pada kelas ini lebih dipengaruhi oleh kualitas citra latih dan uji yang kurang beragam. Sebagian besar citra tidak menampilkan bentuk keriting secara jelas, bahkan ada yang objek daunnya hampir tidak terlihat. Akibatnya, fitur yang diekstraksi menjadi sangat mirip satu sama lain, sehingga model lebih mudah mengenali dan menghasilkan akurasi sempurna. Padahal, dari segi kualitas citra, data pada kelas ini sebenarnya kurang menggambarkan kondisi yang sebenarnya karena gambar yang digunakan tidak begitu jelas. Secara keseluruhan, evaluasi kinerja model SVM-RBF dengan parameter $C=10$ dan $\gamma=0.1$ pada data uji menunjukkan bahwa performa klasifikasi sangat dipengaruhi oleh kualitas citra, kejelasan gejala penyakit, serta tingkat kemiripan antar kelas pada fitur visual. Hasil evaluasi kinerja model ini ditampilkan pada Tabel 7.

Tabel 7. Evaluasi Kinerja Model SVM-RBF ($C=10$, $\gamma=0.1$) pada Data Uji.

Kelas	Presisi	Recall	F1-Score
Bercak daun	84.62%	95.65%	89.79%
Daun keriting	95.83%	100 %	97.87%
Kekurangan nutrisi	84%	91.30%	87.50%
Kutu putih	95.65%	95.65%	95.65%
Virus kuning	91.89%	73.91%	81.90%
Akurasi Total	90%	91.30%	90.94%

4. KESIMPULAN

Penelitian ini membuktikan bahwa kombinasi fitur warna HSV dan tekstur GLCM efektif dalam mengklasifikasikan lima jenis penyakit daun cabai, yaitu bercak daun, daun keriting, kekurangan nutrisi, kutu putih, dan virus kuning. Proses awal seperti peningkatan kualitas gambar dan pemisahan area daun yang sakit terbukti mempermudah model dalam mengenali gejala penyakit. Hasil pengujian dengan metode klasifikasi menggunakan *Support Vector Machine* (SVM) dengan kernel RBF menunjukkan bahwa parameter terbaik diperoleh pada angle 0^0 dan 135^0 , dengan nilai $C = 10$ dan $\gamma = 0.1$, menghasilkan akurasi rata-rata sebesar 91.30%. Walaupun demikian, masih ada beberapa kelas yang sulit dibedakan, terutama virus kuning karena gejalanya mirip dengan bercak daun dan kekurangan nutrisi. Sebaliknya, kelas daun keriting berhasil dikenali dengan sangat baik, meski hal ini lebih dipengaruhi oleh data latih dan uji yang kurang beragam sehingga model lebih mudah mengenalinya. Dengan demikian, sistem ini sudah cukup baik dalam melakukan klasifikasi dan berpotensi untuk digunakan sebagai alat bantu dalam mendeteksi penyakit daun cabai secara otomatis. Namun, kualitas data citra sangat berpengaruh terhadap hasil akhir. Dengan perbaikan pada pengambilan gambar dan variasi data, sistem ini bisa bekerja lebih stabil dan lebih mendekati kondisi nyata di lapangan.

5. SARAN

Saran untuk penelitian, sebaiknya data gambar daun diperbanyak dan dibuat lebih jelas, baik dari segi pencahayaan maupun sudut pengambilan, supaya gejala penyakit bisa terlihat lebih nyata. Hal ini penting karena masih ada kelas yang sulit dibedakan, misalnya virus kuning yang sering mirip dengan bercak daun atau kekurangan nutrisi. Tahap *pre-processing* juga perlu diperbaiki, khususnya pada segmentasi, karena pemisahan objek daun dan latar belakang masih

belum maksimal. Hal ini terjadi terutama pada kelas daun keriting, di mana warna daun sulit dibedakan dari latar belakang yang juga hijau akibat gambar diambil langsung dari pohon. Selain itu, model yang sudah dibuat juga sebaiknya dicoba langsung di lapangan, agar bisa diketahui apakah sistem tetap bekerja dengan baik pada kondisi nyata. Dengan perbaikan data dan pengujian lebih lanjut, hasil klasifikasi bisa lebih stabil dan mendekati kenyataan.

DAFTAR PUSTAKA

- [1] N. Hariyani *et al.*, “Potensi dan Tantangan Pengembangan Sayuran Organik dalam Mendukung Ketahanan Pangan Berkelanjutan Potential and Challenges of Organic Vegetable Development in Supporting Sustainable Food Security,” 2025.
- [2] R. Sianturi and R. Sianturi, “Faktor-Faktor Penentu Adopsi Inovasi Pada Usahatani Cabai Merah (*Capsicum Annum.L.*),” *Jurnal Agriuma*, vol. 6, no. 1, pp. 26–35, Apr. 2024, doi: 10.31289/agri.v6i1.11731.
- [3] A. Bahruddin *et al.*, “Pemanfaatan Dan Prospek Budidaya Cabe Jamu Di Dusun Nung Malaka Desa Daleman Kecamatan Galis Kabupaten Bangkalan,” 2021.
- [4] T. S. Wahyuni, R. Satriani, and A. N. Mandamdari, “Mimbar Agribisnis: Jurnal Pemikiran Masyarakat Ilmiah Berwawasan Agribisnis Pengaruh Fluktuasi Harga Cabai Rawit Merah Terhadap Inflasi di Kabupaten Banyumas The Effect of Fluctuations in Red Cayenne Pepper Prices on Inflation in Banyumas Regency,” vol. 10, no. 2, pp. 1866–1877, Jul. 2024, [Online]. Available: www.antara.jatengnews,
- [5] F. Zikra, K. Usman, and R. Patmasari, “Deteksi Penyakit Cabai Berdasarkan Citra Daun Menggunakan Metode Gray Level Co-Occurrence Matrix Dan Support Vector Machine”.
- [6] S. S. Zuain, H. Fitriyah, and R. Maulana, “Deteksi Penyakit pada Daun Cabai berdasarkan Fitur HSV dan GLCM menggunakan Algoritma C4.5 berbasis Raspberry Pi,” 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [7] S. F. Nazila, Y. Arman, D. Wahyuni, N. Nurhasanah, and Y. S. Putra, “Deteksi Dini Serangan Hama Penyakit pada Cabai Rawit Menggunakan Metode Image Recognition,” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 2, Aug. 2023, doi: 10.28932/jutisi.v9i2.6342.
- [8] S. Adiningsi, B. Pramono, A. M. Sajiah, and R. A. Saputra, “Identifikasi Kualitas Ikan Cakalang Segar Berbasis Citra Mata Menggunakan Metode Support Vector Machine (Svm) Dengan Fungsi Kernel Radial Basis Function,” 2025.
- [9] Z. N. Ali Khan, “Deep Learning-Based CNN Approach for Disease Detection in Chili Plant Leaves.” [Online]. Available: <http://www.ijert.org>
- [10] R. Adawiyah and D. I. Mulyana, “Informasi (Jurnal Informatika dan Sistem Informasi) Optimasi Deteksi Penyakit Kulit Menggunakan Metode Support Vector Machine (SVM) dan Gray Level Co-occurrence Matrix (GLCM).”
- [11] H. P. Hadi and E. H. Rachmawanto, “JIP (Jurnal Informatika Polinema) Ekstraksi Fitur Warna Dan Glcm Pada Algoritma Knn Untuk Klasifikasi Kematangan Rambutan”.
- [12] H. Technology and A. Nexus, “Implementasi Gray Level Co-Occurrence Matrix (GLCM) Untuk Mendeteksi Penyakit Daun Pada Tanaman Holtikultura,” 2025. [Online]. Available: <https://journal.ummat.ac.id/index.php/tcs>
- [13] H. A. Rabbani, M. A. Rahman, and B. Rahayudi, “Perbandingan Ruang Warna RGB dan HSV dalam Klasifikasi Kematangan Biji Kopi,” 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] A. Puteri Bilqis Salsabila *et al.*, “Identifikasi Citra Jenis Bunga menggunakan Algoritma KNN dengan Ekstrasi Warna HSV dan Tekstur GLCM,” *Technomedia Journal (TMJ)*, doi: 10.33050/tmj.v6i1.
- [15] P. Daun, K. Berbasis, F. Glcm, R. Marlita, and D. Mustofa, “Implementasi Support Vector Machine Pada Klasifikasi,” *JIKA : Jurnal Ilmu Komputer dan Aplikasinya*, vol. 1, no. 1, pp. 6–11, 2025, doi: 10.5281/zenodo.14885356.
- [16] D. Margarita, H. Maulana, and E. P. Mandyartha, “Klasifikasi Penyakit Daun Padi Menggunakan Support Vector Machine Berdasarkan Fitur Mendalam (Deep Feature),” *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 4, pp. 2256–2270, Nov. 2024, doi: 10.29100/jipi.v9i4.5634.
- [17] Nana Apriani and Supatman, “5860-Article Text-21097-1-10-20250620,” *Jurnal Informatika Teknologi dan Sains (JINTEKS)*, vol. 7, no. Vol. 7, No. 2, p. 895, May 2025.