

Identification of Leaf Spot Diseases in Eggplant Using Gray Level Co-Occurrence Matrix (GLCM) Feature Extraction and Support Vector Machine (SVM) Classification

Reza Pahlevi, Andika Setiawan*, Rahman Indra Kesuma

Department of Informatics Engineering, Institut Teknologi Sumatera, Lampung, Indonesia
e-mail: reza.pahlevi@student.itera.ac.id, *andika.setiawan@if.itera.ac.id ,
rahman.indra@if.itera.ac.id

Abstract

*Eggplant (*Solanum melongena* L.) is one of the widely cultivated vegetables in Indonesia, belonging to the Solanaceae family. This plant is susceptible to several diseases, one of which is leaf spot disease. Leaf spot disease, caused by the pathogenic fungus *Alternaria* sp., is characterized by irregularly shaped brown spots with a diameter of approximately 0.5 cm. To address this issue, a digital image processing-based system was developed to identify whether the plant is infected. The proposed system employs feature extraction using the Gray Level Co-Occurrence Matrix (GLCM) combined with the Support Vector Machine (SVM) classification algorithm. The study utilized a dataset of 100 images for training and 50 images for testing. The highest achieved accuracy was 100%, obtained by applying Laplace of Gaussian (LoG) edge detection along with Linear Kernel and Polynomial Kernel SVM classifiers.*

Keywords— *Digital Image Processing, Eggplant, Gray Level Co-Occurrence Matrix, Leaf Spot Disease, Support Vector Machine*

Abstrak

*Terung (*Solanum melongena* L.) merupakan salah satu jenis sayuran yang banyak dibudidayakan di Indonesia dan termasuk dalam famili Solanaceae. Tanaman ini rentan terhadap beberapa penyakit, salah satunya adalah bercak daun. Penyakit bercak daun disebabkan oleh jamur patogen *Alternaria* sp., yang ditandai dengan bercak berwarna coklat, berbentuk tidak beraturan, dengan diameter sekitar 0,5 cm. Untuk membantu proses identifikasi penyakit tersebut, penelitian ini mengembangkan sistem berbasis pengolahan citra digital untuk mendeteksi infeksi pada tanaman terung. Sistem yang dikembangkan menggunakan metode ekstraksi ciri Gray Level Co-Occurrence Matrix (GLCM) serta algoritma klasifikasi Support Vector Machine (SVM). Penelitian ini memanfaatkan 100 citra sebagai data latih dan 50 citra sebagai data uji. Hasil terbaik menunjukkan akurasi hingga 100%, dengan deteksi tepi menggunakan Laplace of Gaussian (LoG) serta klasifikasi SVM Linear Kernel dan Polynomial Kernel.*

Kata kunci— *Bercak Daun, Gray Level Co-Occurrence Matrix, Pengolahan Citra Digital, Support Vector Machine, Terung*

1. PENDAHULUAN

Terung (*Solanum melongena* L.) merupakan salah satu jenis sayuran yang banyak dibudidayakan di Indonesia dan termasuk dalam famili Solanaceae. Buah terung umumnya dikonsumsi masyarakat sebagai sayuran atau lalapan [1]. Sayuran ini juga mengandung berbagai nutrisi penting, seperti kalsium, protein, karbohidrat, vitamin A, vitamin B, vitamin C, fosfor, dan zat besi [2].

Beberapa penyakit dapat menyerang tanaman terung, di antaranya bercak daun dan antraknosa [3], [4]. Penyakit bercak daun disebabkan oleh jamur patogen *Alternaria* sp., yang ditandai dengan bercak berwarna coklat berbentuk tidak beraturan dengan diameter sekitar 0,5 cm [5]. Sementara itu, penyakit antraknosa menyerang buah terung, ditandai dengan bercak yang cekung ke dalam, berwarna coklat tua, dengan ukuran berkisar antara 2 hingga 5 cm serta ditumbuhi miselium. Bercak pada daun dapat meluas dan menimbulkan bintik hitam di bagian tengahnya. Jika dibiarkan, kondisi ini dapat menyebabkan buah terung mengering, mengerut, bahkan membusuk [6]. Dampaknya, hasil produksi terung menurun sehingga merugikan petani..

Untuk mendeteksi apakah tanaman terung terserang penyakit atau tidak, teknologi digital kini dapat dimanfaatkan [7] salah satunya melalui pengolahan citra. Dengan pemanfaatan teknologi ini, diharapkan deteksi dini penyakit pada tanaman dapat dilakukan secara lebih efektif. Oleh karena itu, penelitian ini dilakukan untuk mengidentifikasi penyakit pada terung menggunakan teknik pengolahan citra digital [8] sebagai solusi atas permasalahan tersebut.

Beberapa studi sebelumnya telah mengkaji identifikasi penyakit tanaman dengan berbagai pendekatan. Misalnya, Sari [4] melakukan deteksi penyakit pada tanaman jagung menggunakan metode *Color Moments* dan GLCM, dengan tingkat akurasi mencapai 89,375% [9]. Penelitian lain menggunakan kombinasi GLCM dan SVM untuk mengenali penyakit pada daun tembakau, menghasilkan rata-rata akurasi 74%, dengan hasil terbaik 80% pada kernel polynomial pada jarak piksel tertentu, dan terendah 63% pada kernel gaussian [10]. Metode SVM juga digunakan untuk mengklasifikasikan penyakit daun kentang dengan tingkat akurasi 80% [11]. Sementara itu, penelitian yang menggunakan KNN untuk mendeteksi penyakit daun jagung memperoleh akurasi sebesar 73,3% [12]. Studi lain memanfaatkan GLCM dan KNN untuk mengenali penyakit busuk batang pada buah naga, menghasilkan akurasi 87% [12]. Terakhir, kombinasi GLCM dan backpropagation diterapkan untuk identifikasi penyakit pada padi, dengan akurasi mencapai 93% dari 30 sampel uji [[13].

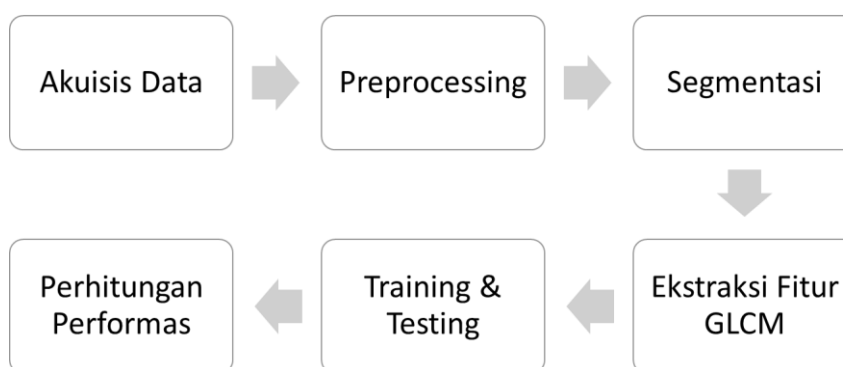
Namun, penelitian-penelitian sebelumnya belum pernah secara spesifik mengkaji penyakit pada tanaman terung dan juga belum berfokus pada satu jenis penyakit tertentu, sehingga tingkat akurasi yang diperoleh belum optimal. Berdasarkan hal tersebut, penelitian ini difokuskan pada identifikasi penyakit pada tanaman terung, khususnya penyakit bercak daun yang sering menyerang tanaman ini. Penelitian hanya menitikberatkan pada satu jenis penyakit dengan menggunakan *dataset* berupa 100 citra untuk pelatihan (*training*) dan 50 citra untuk pengujian (*testing*), sehingga hasil yang diperoleh diharapkan lebih optimal. Metode yang digunakan dalam penelitian ini mengombinasikan dua algoritma, yaitu *Gray Level Co-occurrence Matrix* (GLCM) untuk mengekstraksi ciri dari citra daun terung, serta *Support Vector Machine* (SVM) untuk melakukan proses klasifikasi guna menentukan apakah daun tergolong sehat atau terinfeksi bercak daun.

Penelitian ini bertujuan untuk mengembangkan metode yang dapat mengidentifikasi penyakit bercak daun pada tanaman terung menggunakan teknik ekstraksi ciri *Gray Level Co-occurrence Matrix* (GLCM) dan klasifikasi *Support Vector Machine* (SVM). Studi ini diharapkan dapat menghasilkan sebuah sistem yang akurat dalam mendeteksi penyakit, dengan menggunakan total 150 citra yang terbagi menjadi 100 data training dan 50 data testing. Citra yang digunakan harus memiliki latar belakang putih dan diambil pada kondisi cahaya yang memadai, dengan seluruh proses pengolahan citra dilakukan menggunakan MATLAB. Dengan demikian, hasilnya diharapkan memberikan manfaat praktis, terutama bagi petani di Kabupaten Tanggamus, dengan

menyediakan alat bantu yang dapat mendeteksi penyakit bercak daun secara dini, sehingga tindakan preventif dapat segera diambil untuk mengurangi kerugian produksi.

2. METODE PENELITIAN

Tanaman terung (*Solanum melongena L.*) merupakan salah satu komoditas sayuran yang banyak dibudidayakan di wilayah Kabupaten Tanggamus. Namun demikian, tanaman ini kerap terserang berbagai penyakit, salah satunya adalah bercak daun yang disebabkan oleh *Alternaria sp* [4], [14], [15]. Serangan penyakit tersebut berdampak pada penurunan kualitas dan kuantitas hasil panen, sehingga merugikan petani. Untuk menjawab permasalahan tersebut, penelitian ini menawarkan solusi berupa identifikasi citra tanaman terung melalui ekstraksi fitur menggunakan metode GLCM dan klasifikasi dengan SVM. Tahapan lengkap dari penelitian ini disajikan pada Gambar 1.



Gambar 1 Tahapan Penelitian

2.1 Akuisisi Data

Data diperoleh dalam bentuk citra daun terung, mencakup daun sehat maupun yang terinfeksi penyakit bercak daun. Pengambilan data dilakukan di Desa Simpangkanan, Kecamatan Sumberejo, Kabupaten Tanggamus. Secara keseluruhan terkumpul 150 citra, terdiri dari 50 citra daun sehat dan 50 citra daun berpenyakit untuk keperluan *training*, serta 25 citra daun sehat dan 25 citra daun berpenyakit untuk *testing*. Citra diambil menggunakan kamera smartphone Oppo A37f dengan resolusi 8 MP. Seluruh pengambilan gambar dilakukan dengan pencahayaan yang cukup dan latar belakang kertas putih, untuk mempermudah proses segmentasi pada tahap pengolahan citra.

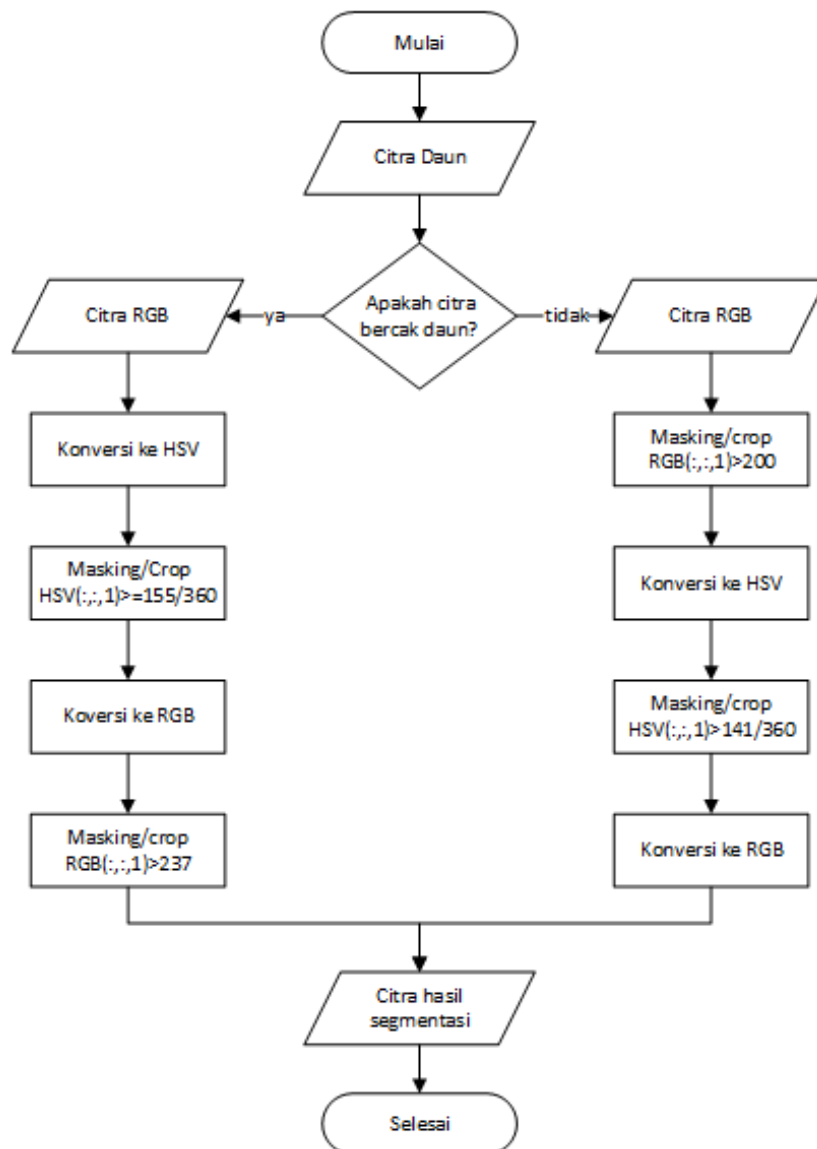
2.2 Pre-processing

Pada tahap ini, dilakukan proses pemotongan citra (*cropping*) dengan rasio 3:4, diikuti dengan penyesuaian ukuran (*resizing*) agar seluruh gambar memiliki dimensi seragam, yaitu 500×375 piksel. Setelah proses tersebut selesai, semua citra disimpan dan dikelompokkan ke dalam dua folder terpisah, yaitu *dataTrain* dan *dataTest*. Folder *dataTest* berisi 50 citra, terdiri atas 25 gambar daun terung yang terinfeksi bercak daun dengan penamaan 1–25, serta 25 gambar daun sehat dengan penamaan 26–50. Sementara itu, folder *dataTrain* menyimpan 100 citra, yang terdiri dari 50 gambar daun berpenyakit bercak daun bernomor 1–50, dan 50 gambar daun sehat bernomor 51–100.

2.2 Segmentasi

Proses segmentasi bertujuan untuk memisahkan objek utama dari latar belakang dengan memanfaatkan metode deteksi tepi [16] seperti diperlihatkan pada Gambar 2. Pada tahap ini, segmentasi dilakukan menggunakan teknik *masking color* berbasis HSV. Citra daun bercak dan citra daun sehat memiliki tahapan segmentasi serta parameter yang berbeda, menyesuaikan

dengan karakteristik masing-masing citra. Untuk citra daun bercak, langkah awal yaitu mengonversi citra dari format RGB ke HSV. Kemudian dilakukan proses *masking* dengan menghilangkan piksel yang memiliki nilai hue $\geq 155/360$. Setelah *masking*, masih terdapat sebagian latar belakang yang tidak terbuang karena berada di luar rentang hue tersebut; untuk mengatasinya, dilakukan *masking* tambahan dengan menghapus piksel bernilai lebih dari 237. Setelah itu, citra dikonversi kembali ke format RGB. Citra hasil segmentasi daun bercak disimpan pada folder *segmenTest* dengan penamaan 1–25, dan pada folder *segmenTrain* dengan penamaan 1–50. Sementara itu, untuk citra daun sehat, tahap awal segmentasi dilakukan dengan menghapus piksel bernilai lebih dari 200, kemudian citra dikonversi ke HSV dan dilakukan *masking* kembali dengan menghilangkan piksel dengan nilai hue $> 141/360$.




Gambar 2 Alur segmentasi

Selanjutnya, citra dikonversi kembali ke format RGB. Hasil segmentasi citra daun sehat kemudian disimpan pada folder *segmenTest* dengan penamaan berurutan dari 26 hingga 50, serta pada folder *segmenTrain* dengan penamaan 51 hingga 100. Segmentasi dianggap berhasil apabila seluruh bagian daun dan tangkainya tetap utuh, tanpa ada bagian yang terpotong atau hilang sebagian maupun seluruhnya. Setelah tahap segmentasi, citra diproses lebih lanjut melalui konversi ke skala abu-abu (*grayscale*) dan dilanjutkan dengan penerapan metode deteksi tepi.

Metode deteksi tepi yang digunakan dalam penelitian ini meliputi Canny, Sobel, Prewitt, Roberts, serta Laplacian of Gaussian (LoG).

2.3 Ekstraksi Fitur GLCM

Pada tahap ini dilakukan proses ekstraksi fitur menggunakan metode GLCM terhadap citra yang telah diperoleh dari hasil segmentasi sebelumnya. Ekstraksi ini menghasilkan sejumlah fitur penting, yaitu *energy*, *contrast*, *homogeneity*, dan *correlation*, yang digunakan sebagai parameter dalam analisis selanjutnya.



Gambar 3 Ilustrasi menghitung GLCM

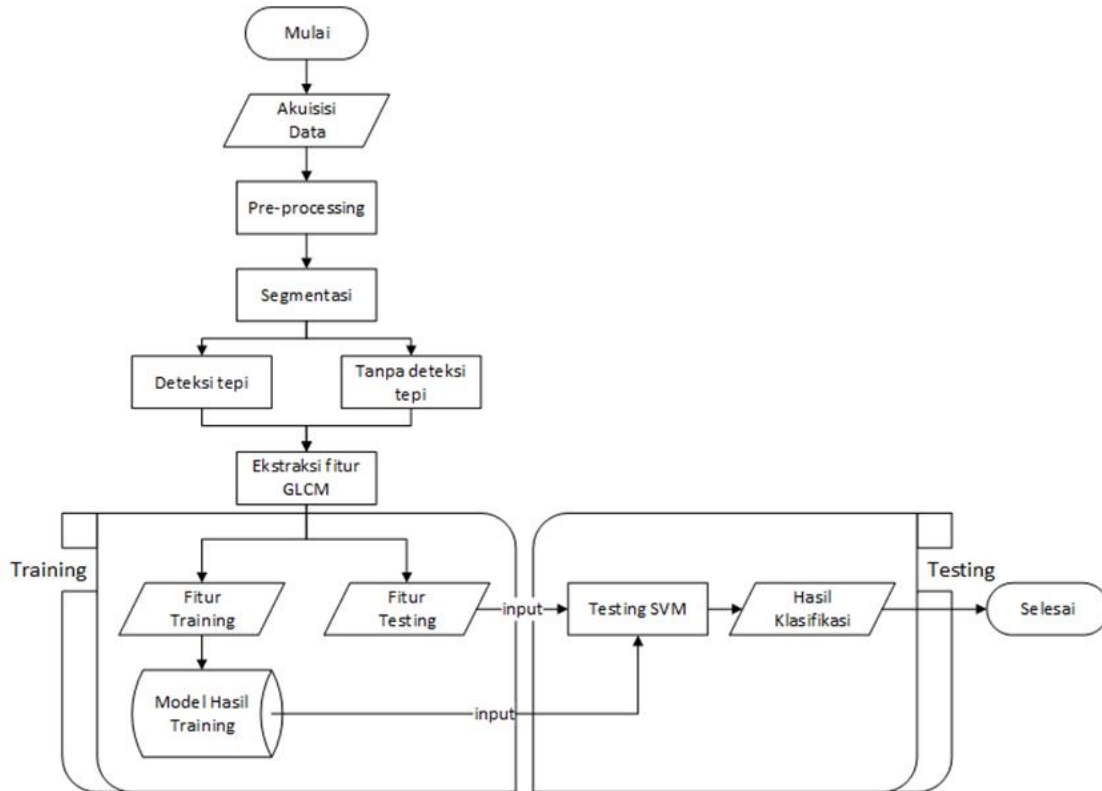
Langkah-langkah untuk menghitung *Gray Level Co-occurrence Matrix* (GLCM) melibatkan proses yang detail dan terstruktur ditampilkan pada Gambar 3. Pertama, ambil contoh citra 3-bit sebagai dasar. Tentukan jarak d dan sudut θ , dengan sudut yang bisa menggunakan 0° , 45° , 90° , atau 135° . Misalnya, pilih $d=1$ dan $\theta=0^\circ$. Langkah berikutnya adalah membentuk matriks kookurensi. Mulai dengan menentukan nilai terbesar di dalam matriks citra. Bentuk matriks baru dengan ukuran berdasarkan nilai maksimum yang ditemukan, yaitu Matriks (nilai max) x (nilai max). Isi matriks baru ini dengan menghitung kemunculan pasangan nilai di matriks awal pada sudut 0° dan jarak 1, sesuai dengan nilai indeks di matriks baru. Sebagai contoh, untuk indeks (0,0), cari berapa kali pasangan nilai 0,0 muncul di matriks awal dan catat jumlahnya pada indeks (0,0) di matriks baru. Lanjutkan perhitungan ini hingga indeks (4,4). Setelah itu, lakukan normalisasi dengan membagi nilai di setiap indeks matriks baru dengan jumlah total nilai di semua indeks. Dengan matriks GLCM yang telah terbentuk, kita kemudian dapat menghitung nilai dari tiap fitur yang diinginkan.

2.3 Training dan Testing

Alur proses *training* dan *testing* ditunjukkan pada Gambar 4. Setelah dilakukan ekstraksi fitur menggunakan metode GLCM, diperoleh himpunan fitur *training* yang kemudian dilengkapi dengan label kelas, yaitu daun sehat dan daun berpenyakit. Nilai-nilai fitur tersebut selanjutnya digunakan sebagai data input dalam tahap pelatihan model SVM. Melalui tahap pelatihan, diperoleh sebuah *hyperplane* optimal yang berperan sebagai batas pemisah antara dua kelas, yaitu daun sehat dan daun yang terinfeksi penyakit. *Hyperplane* ini digunakan untuk mengklasifikasikan data pada tahap pengujian. Dalam implementasi SVM, digunakan dua pendekatan, yaitu linear dan non-linear. Jika fitur yang dihasilkan membentuk model yang tidak linear, maka kernel digunakan untuk mengatasinya. Pada penelitian ini dipilih kernel polinomial karena pada penelitian sebelumnya metode ini menunjukkan akurasi yang lebih tinggi. Tahap pengujian menghasilkan keluaran berupa klasifikasi kondisi daun, apakah sehat atau terinfeksi penyakit.

Pada tahap *training*, data yang digunakan berupa nilai fitur GLCM dari 100 citra latih. Empat parameter fitur GLCM yang diproses meliputi *contrast*, *correlation*, *energy*, dan

homogeneity, yang kemudian digunakan untuk membentuk model klasifikasi. Selanjutnya, pada tahap *testing*, data yang diproses juga menggunakan empat nilai fitur GLCM yang sama, dikombinasikan dengan model hasil pelatihan sebelumnya. Dengan demikian, sistem mampu melakukan klasifikasi citra ke dalam salah satu dari dua kelas, yaitu bercak daun atau daun sehat.



Gambar 4 Alur *training* dan *testing*

2.4 Perhitungan Performa

Langkah berikutnya adalah menghitung performa atau tingkat akurasi dari hasil klasifikasi yang telah diperoleh. Perhitungan ini dilakukan dengan memanfaatkan *confusion matrix* dan menggunakan rumus yang dinyatakan pada Persamaan (1).

$$k(x, y) = (1 + x, y)^q \quad \text{Dimana } q = 1, 2, \dots, N \quad (1)$$

3. HASIL DAN PEMBAHASAN

Dalam bagian ini, peneliti memaparkan dan menganalisis hasil eksperimen yang telah dilakukan secara sistematis, serta membahas secara mendalam pengaruh hasil tersebut terhadap pengembangan metode identifikasi penyakit bercak daun pada tanaman terung. Analisis ini juga mencakup evaluasi efektivitas metode yang digunakan dan sejauh mana pendekatan tersebut dapat diandalkan untuk klasifikasi citra daun.

3.1 Akuisisi Data

Tahap ini menghasilkan total 150 citra, terdiri atas 75 citra daun terung sehat dan 75 citra daun yang mengalami bercak penyakit. Semua citra diambil dengan latar belakang putih untuk memudahkan proses segmentasi dan ekstraksi fitur. Contoh hasil citra dari proses akuisisi ditampilkan pada Gambar 5 sebagai representasi data awal yang digunakan dalam penelitian.



Gambar 5 Akuisisi citra daun sakit dan daun sehat


3.2 Pre-processing

Pada tahap ini akan menghasilkan citra yang memiliki rasio 3x4, ukuran 500x375 piksel seperti yang ditunjukkan pada Gambar 6, tangkai daun berada di atas, dan nama berurutan 1 – 50 untuk testing disimpan dalam folder dataTest, dan 1-100 untuk training disimpan dalam folder dataTrain. Selanjutnya akan dilakukan segmentasi.

Gambar 6 Citra daun sehat dan sakit hasil *pre-processing*

3.3 Segmentasi

Citra hasil segmentasi dengan latar belakang berwarna hitam ditunjukkan pada Gambar 7, hanya memfokuskan pada objek daun dan mencapai efektivitas 100% tanpa bagian daun atau tangkai yang terpotong atau hilang, sehingga semua citra siap untuk diproses lebih lanjut. Keberhasilan ini didukung oleh kualitas citra yang baik dari proses akuisisi dan latar belakang putih yang memfasilitasi segmentasi. Gambar 4 juga menunjukkan citra hasil dari pendeteksian tepi, yang menghasilkan citra biner dengan pola daun yang jelas; teknik deteksi tepi *Canny* dan *Laplace of Gaussian* (LoG) memberikan hasil yang mirip dengan pola daun yang sangat jelas, berbeda dengan hasil dari Prewitt, Robert, dan Sobel yang kurang mendetail, mempengaruhi nilai fitur ekstraksi yang diperoleh dan akhirnya memengaruhi akurasi klasifikasi yang dicapai.



Gambar 7 Proses segmentasi citra

3.4 Ekstraksi Fitur GLCM

Representasi hasil dari fitur GLCM tanpa deteksi tepi penelitian ini ditunjukkan pada Gambar 8, hasil tersebut didapatkan dari citra testing bercak1, bercak2, sehat1, dan sehat2. Dari kedua kelas tersebut bisa diambil kesimpulan bahwa rata-rata nilai *Contrast* dan *Correlation* pada kelas bercak daun lebih besar daripada daun sehat serta nilai *Energy* dan *Homogeneity* pada kelas bercak daun lebih kecil daripada daun yang sehat. Akan tetapi terdapat nilai yang tidak konsisten pada kedua kelas tersebut, terkadang lebih kecil bercak daun ataupun sebaliknya.

Citra	Jarak	Contrast				Correlation				Energy				Homogeneity			
		0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°
bercak1	1	0.2784	0.34128	0.23123	0.3226	0.94853	0.93691	0.95725	0.94036	0.26797	0.26028	0.26834	0.26171	0.93693	0.92164	0.93729	0.92474
	2	0.45965	0.52624	0.37235	0.49627	0.91503	0.9027	0.93115	0.90824	0.25392	0.24877	0.25643	0.25023	0.90774	0.89888	0.91153	0.90205
	3	0.59197	0.68034	0.4644	0.64103	0.89057	0.8742	0.91413	0.88147	0.24713	0.24015	0.25139	0.24226	0.89454	0.88312	0.90154	0.88759
	4	0.7149	0.83122	0.54452	0.77453	0.86785	0.84626	0.89929	0.85674	0.24122	0.23187	0.24685	0.23477	0.88396	0.86782	0.89311	0.87423
	5	0.83497	0.97633	0.62273	0.89442	0.84565	0.81937	0.88481	0.83452	0.23516	0.22452	0.24226	0.22806	0.87257	0.8548	0.88425	0.86256
bercak2	1	0.36552	0.40852	0.29314	0.43272	0.93268	0.92475	0.94601	0.92029	0.21653	0.21166	0.22048	0.21061	0.91593	0.90508	0.92555	0.90171
	2	0.58179	0.5954	0.45585	0.63097	0.89282	0.89027	0.91603	0.88371	0.2041	0.20195	0.20839	0.20104	0.88345	0.88265	0.89496	0.87971
	3	0.71133	0.75513	0.54734	0.80005	0.86892	0.86076	0.89916	0.85248	0.19925	0.19441	0.20406	0.19377	0.87368	0.86618	0.88532	0.86459
	4	0.84019	0.90615	0.63597	0.96279	0.84513	0.83282	0.88281	0.82237	0.19422	0.18756	0.2001	0.18662	0.86289	0.85145	0.87666	0.84949
	5	0.97053	1.04962	0.7279	1.11978	0.82106	0.80621	0.86583	0.79326	0.18896	0.18136	0.19604	0.18025	0.851	0.8385	0.86732	0.8363
sehat1	1	0.27055	0.28596	0.21983	0.28323	0.90456	0.89912	0.92242	0.90008	0.2874	0.28247	0.29242	0.28378	0.92	0.91035	0.93078	0.91386
	2	0.38164	0.35843	0.30456	0.36031	0.86541	0.87359	0.89252	0.87293	0.27532	0.2746	0.28062	0.27547	0.89462	0.89894	0.90688	0.90113
	3	0.41244	0.4185	0.32289	0.41275	0.8546	0.85245	0.88605	0.85448	0.27186	0.26838	0.27768	0.26911	0.89299	0.89156	0.90478	0.89343
	4	0.45036	0.46643	0.34513	0.45907	0.84128	0.83559	0.8782	0.83819	0.26787	0.26207	0.27454	0.26294	0.88955	0.88407	0.90197	0.88643
	5	0.49178	0.51103	0.37417	0.50346	0.82673	0.81991	0.86795	0.82258	0.26294	0.25644	0.2705	0.2571	0.88321	0.87845	0.89652	0.88008
sehat2	1	0.27861	0.32278	0.25282	0.3028	0.89414	0.87736	0.90392	0.88495	0.30437	0.29843	0.30554	0.29821	0.92458	0.91343	0.92673	0.91406
	2	0.39108	0.40253	0.34123	0.37323	0.85143	0.84706	0.87031	0.85819	0.29221	0.28964	0.29431	0.29	0.90137	0.90148	0.9055	0.90264
	3	0.42918	0.4697	0.35572	0.43513	0.83699	0.82155	0.86479	0.83469	0.28793	0.28215	0.2916	0.2829	0.89786	0.89246	0.90496	0.89347
	4	0.47688	0.53349	0.38844	0.48935	0.8189	0.79732	0.85234	0.81408	0.28314	0.27503	0.28738	0.2763	0.89228	0.88359	0.90018	0.8855
	5	0.52653	0.58818	0.42576	0.53897	0.80007	0.77652	0.83813	0.79522	0.2779	0.26881	0.28244	0.27014	0.88534	0.8765	0.89352	0.87837

Gambar 8 Fitur GLCM daun tanpa deteksi tepi

Adapun hasil dari fitur GLCM tanpa deteksi tepi *Canny* terlihat pada Gambar 9, hasil tersebut didapatkan dari citra testing bercak1, bercak2, sehat1, dan sehat2. Dari kedua kelas tersebut bisa diambil kesimpulan bahwa rata-rata nilai *Contrast* dan *Correlation* pada kelas bercak daun lebih kecil daripada daun sehat serta nilai *Energy* dan *Homogeneity* pada kelas bercak daun lebih besar daripada daun yang sehat. Nilai fitur yang didapatkan juga sebagian besar sudah cukup konsisten dan hanya ada beberapa citra saja yang nilainya tidak konsisten lebih kecil atau lebih besar di antara dua kelas tersebut.

Citra	Jarak	Contrast				Correlation				Energy				Homogeneity			
		0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°
bercak1	1	0.1081	0.13679	0.10278	0.12728	0.35279	0.18248	0.38428	0.2393	0.73657	0.7146	0.74087	0.7216	0.94595	0.93161	0.94861	0.93636
	2	0.15293	0.14891	0.14752	0.14294	0.08654	0.11374	0.11775	0.14924	0.70303	0.70525	0.70703	0.70947	0.92353	0.92555	0.92624	0.92853
	3	0.1553	0.15138	0.15058	0.14672	0.07463	0.10252	0.10082	0.13016	0.70099	0.70286	0.70463	0.70613	0.92235	0.92431	0.92471	0.92664
	4	0.15142	0.15222	0.14646	0.15132	0.09995	0.10095	0.12662	0.10628	0.70328	0.70164	0.7073	0.70227	0.92429	0.92389	0.92677	0.92434
	5	0.15244	0.15457	0.14726	0.15404	0.09605	0.09055	0.12305	0.0937	0.70216	0.69936	0.70649	0.69973	0.92378	0.92271	0.92637	0.92298
bercak2	1	0.1289	0.14779	0.11025	0.15442	0.30981	0.21004	0.40933	0.17464	0.70096	0.68696	0.71526	0.68234	0.93555	0.9261	0.94488	0.92279
	2	0.17515	0.16233	0.15983	0.16621	0.06435	0.1359	0.1452	0.11527	0.66833	0.67616	0.67874	0.67355	0.91242	0.91883	0.92009	0.9169
	3	0.17214	0.16616	0.16334	0.16649	0.08263	0.11919	0.12799	0.11742	0.66985	0.67281	0.67603	0.67258	0.91393	0.91692	0.91833	0.91675
	4	0.17135	0.16958	0.1626	0.1712	0.08899	0.10469	0.13339	0.09614	0.66992	0.66977	0.67622	0.6687	0.91432	0.91521	0.9187	0.9144
	5	0.17254	0.17305	0.16655	0.1746	0.08486	0.09005	0.11379	0.08189	0.66869	0.66672	0.67325	0.66571	0.91373	0.91348	0.91672	0.9127
sehat1	1	0.17696	0.20717	0.1473	0.19169	0.26831	0.14483	0.3906	0.20875	0.6125	0.59349	0.63268	0.6028	0.91152	0.89641	0.92635	0.90416
	2	0.23234	0.20595	0.20899	0.20371	0.04147	0.15311	0.13684	0.16238	0.57924	0.59326	0.59257	0.59459	0.88383	0.89703	0.89551	0.89814
	3	0.21159	0.20569	0.20422	0.20597	0.12904	0.15754	0.1579	0.15638	0.59024	0.59247	0.59497	0.59231	0.8942	0.89716	0.89789	0.89702
	4	0.20892	0.20753	0.20303	0.21039	0.14198	0.1533	0.16419	0.1416	0.59124	0.59044	0.59527	0.58877	0.89554	0.89624	0.89848	0.8948
	5	0.21054	0.21225	0.20555	0.21275	0.13726	0.13738	0.15521	0.13534	0.58975	0.58674	0.59338	0.58645	0.89473	0.89387	0.89722	0.89362
sehat2	1	0.15752	0.18858	0.14791	0.18552	0.31189	0.1776	0.35349	0.19097	0.63838	0.61768	0.64518	0.6196	0.92124	0.90571	0.92604	0.90724
	2	0.21181	0.19081	0.20225	0.19623	0.07664	0.17097	0.11742	0.14744	0.60366	0.61544	0.60949	0.61212	0.89409	0.90459	0.89887	0.90189
	3	0.20151	0.19643	0.19333	0.20107	0.12346	0.14981	0.15776	0.12973	0.60921	0.61112	0.6145	0.60832	0.89925	0.90179	0.90333	0.89947
	4	0.19926	0.19928	0.19457	0.19944	0.13504	0.1407	0.15378	0.13999	0.61008	0.60853	0.61336	0.60843	0.90037	0.90036	0.90272	0.90028
	5	0.20176	0.20263	0.19948	0.20255	0.12593	0.12938	0.13382	0.12971	0.60812	0.60569	0.61002	0.60574	0.89912	0.89869	0.90026	0.89873

Gambar 9 Fitur GLCM daun deteksi tepi *Canny*

Hasil dari fitur GLCM tanpa deteksi tepi dapat dilihat pada Gambar 10, hasil tersebut didapatkan dari citra testing bercak1, bercak2, sehat1, dan sehat2. Dari kedua kelas tersebut bisa diambil kesimpulan bahwa rata-rata nilai *Contrast* dan *Correlation* pada kelas bercak daun lebih kecil daripada daun sehat serta nilai *Energy* dan *Homogeneity* pada kelas bercak daun lebih besar daripada daun yang sehat. Nilai fitur yang didapatkan juga sebagian besar sudah cukup konsisten dan hanya ada beberapa citra saja yang nilainya tidak konsisten lebih kecil atau lebih besar di antara dua kelas tersebut. Berdasarkan hasil yang telah didapatkan tersebut dapat diambil

kesimpulan bahwa citra bercak daun cenderung memiliki nilai *Contrast* dan *Correlation* yang lebih kecil serta nilai *Energy* dan *Homogeneity* yang lebih besar dibandingkan dengan citra daun sehat.

Citra	Jarak	Contrast				Correlation				Energy				Homogeneity			
		0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°	0°	45°	90°	135°
bercak1	1	0.02688	0.02899	0.02412	0.02673	0.20903	0.14831	0.2894	0.21474	0.93987	0.93782	0.94251	0.93995	0.98656	0.98551	0.98794	0.98664
	2	0.02955	0.03104	0.02802	0.02989	0.1325	0.09191	0.17609	0.12561	0.93725	0.93574	0.93877	0.93682	0.98522	0.98448	0.98599	0.98506
	3	0.03081	0.03239	0.02962	0.03163	0.09815	0.05515	0.12912	0.07724	0.93598	0.93438	0.93725	0.93509	0.9846	0.98381	0.98519	0.98418
	4	0.03151	0.03308	0.03067	0.03205	0.07985	0.03695	0.09756	0.06701	0.93523	0.93367	0.93628	0.93463	0.98424	0.98346	0.98466	0.98398
	5	0.03218	0.03348	0.03149	0.03268	0.06281	0.02694	0.07255	0.05011	0.93451	0.93324	0.93555	0.93399	0.98391	0.98326	0.98426	0.98366
bercak2	1	0.03032	0.02846	0.02146	0.03003	0.12703	0.18212	0.3817	0.13717	0.93587	0.93755	0.94429	0.93607	0.98484	0.98577	0.98927	0.98499
	2	0.03079	0.0312	0.025	0.03172	0.11591	0.10753	0.28129	0.09275	0.93534	0.93481	0.94085	0.93432	0.98461	0.9844	0.9875	0.98414
	3	0.03174	0.03237	0.02731	0.03263	0.09092	0.0785	0.21629	0.07111	0.93435	0.93356	0.93859	0.93332	0.98413	0.98382	0.98634	0.98369
	4	0.03326	0.03363	0.02849	0.03387	0.04992	0.04615	0.18319	0.03937	0.93284	0.93225	0.93743	0.93203	0.98337	0.98319	0.98575	0.98307
	5	0.03366	0.03369	0.02934	0.03451	0.04094	0.04827	0.16013	0.02513	0.93237	0.93204	0.93658	0.93128	0.98317	0.98315	0.98533	0.98274
sehat1	1	0.04077	0.03577	0.02845	0.03424	0.07239	0.18751	0.35209	0.22231	0.91694	0.92148	0.92845	0.92291	0.97961	0.98211	0.98577	0.98288
	2	0.03715	0.03801	0.03065	0.03698	0.15702	0.14048	0.30322	0.16361	0.92017	0.91922	0.9263	0.92016	0.98143	0.981	0.98467	0.98151
	3	0.04066	0.04045	0.03315	0.04032	0.07982	0.08928	0.24774	0.0922	0.91681	0.91678	0.92389	0.9169	0.97967	0.97978	0.98343	0.97984
	4	0.04252	0.04214	0.03567	0.04119	0.04009	0.05534	0.19199	0.07654	0.91499	0.91503	0.92146	0.9159	0.97874	0.97893	0.98217	0.9794
	5	0.04302	0.04266	0.03685	0.04135	0.03151	0.04771	0.16667	0.07696	0.91442	0.91435	0.92029	0.91555	0.97849	0.97867	0.98158	0.97932
sehat2	1	0.04063	0.03884	0.03497	0.03748	0.16395	0.20207	0.27996	0.23003	0.91243	0.914	0.91777	0.91526	0.97969	0.98058	0.98252	0.98126
	2	0.04029	0.04304	0.04341	0.0429	0.17275	0.11947	0.29474	0.12233	0.91262	0.90994	0.91822	0.91007	0.97985	0.97848	0.98285	0.97855
	3	0.0439	0.04575	0.04204	0.04421	0.10094	0.06765	0.13713	0.09917	0.9092	0.90727	0.911	0.90868	0.97805	0.97712	0.97898	0.9779
	4	0.04534	0.04639	0.04336	0.04628	0.07341	0.05836	0.11158	0.06056	0.90778	0.9065	0.90971	0.9066	0.97733	0.97681	0.97832	0.97686
	5	0.04665	0.04726	0.0444	0.04715	0.0489	0.0444	0.09177	0.04661	0.90647	0.90551	0.90869	0.90561	0.97667	0.97637	0.9778	0.97642

Gambar 10 Fitur GCLM daun deteksi tepi Sobel

3.5 Training dan Testing

Hasil keluaran yang didapatkan di tahap ini yaitu berupa angka 1 dan 2. Angka 1 menunjukkan bahwa citra tersebut terdeteksi bercak daun, sedangkan angka 2 menunjukkan bahwa citra tersebut daun sehat. Pada SVM *Polynomial Kernel* parameter yang digunakan yaitu $cost = 1$ dan $degree = 3$.

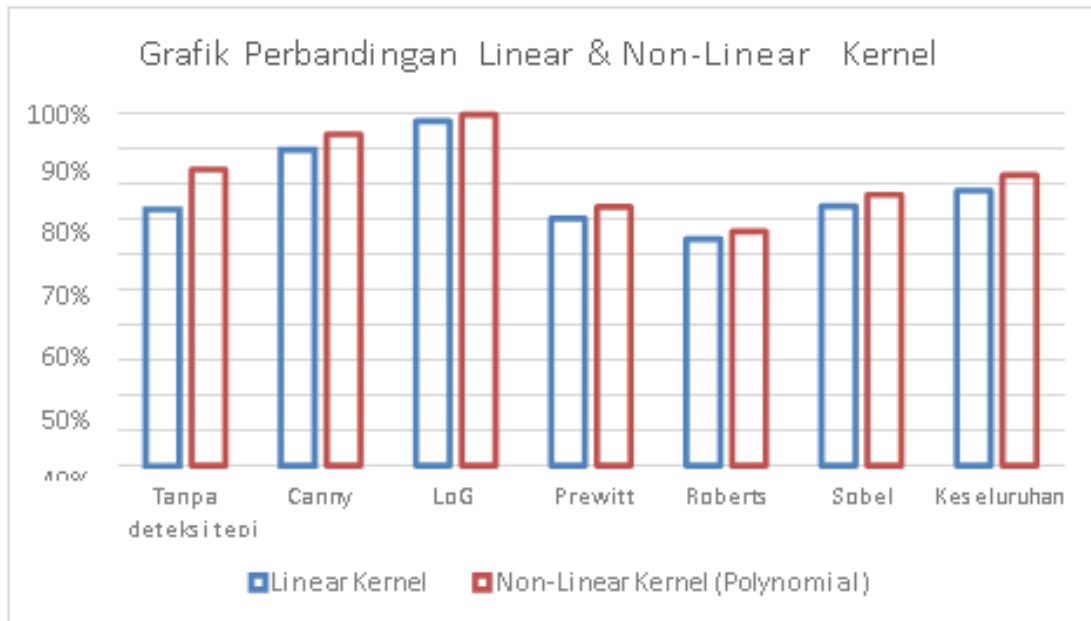
Citra	1				2				3				4				5			
	0	45	90	135	0	45	90	135	0	45	90	135	0	45	90	135	0	45	90	135
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
5	1	1	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
6	1	1	1	1	1	1	1	1	1	1	1	1	2	2	1	1	2	2	2	2
7	1	1	1	1	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2
8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
10	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
11	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
12	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
13	1	1	1	1	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
14	1	1	1	1	1	1	1	1	2	2	1	1	2	2	1	2	2	2	2	1
15	1	1	1	1	1	1	1	2	1	1	1	2	2	1	1	2	1	1	1	1
16	1	1	1	2	1	2	1	2	1	2	2	1	2	1	2	1	1	1	2	1
17	1	1	1	1	1	2	1	1	2	2	1	1	2	2	1	1	1	1	2	1
18	1	1	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
19	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
20	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
21	1	1	1	1	1	1	1	2	2	1	1	2	2	1	1	2	1	1	2	1
22	1	1	1	1	2	2	1	2	2	2	1	2	2	2	1	2	2	1	1	1
23	1	1	1	1	2	2	1	2	2	2	1	2	2	2	2	2	2	2	2	1
24	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2	1
25	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
26	1	1	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
27	1	1	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
28	1	1	1	1	1	1	1	1	2	2	1	2	2	2	2	2	2	2	2	2
29	1	1	1	1	1	1	1	1	2	2	1	2	2	2	2	2	2	2	2	2
30	1	1	1	1	1	1	1	1	1	2	1	2	2	2	2	2	2	2	2	2
31	1	1	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
32	1	1	1	1	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2
33	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
34	1	1	1	1	1	1	1	1	1	2	1	1	2	2	1	2	2	2	1	2
35	1	1	1	1	2	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2
36	1	1	1	1	1	1	1	1	1	2	1	2	2	2	1	2	2	2	1	2
37	1	1	1	1	1	1	1	1	1	2	1	2	2	2	1	2	2	2	1	2
38	1	1	2	1	1	1	1	1	1	2	1	2	2	2	2	2	2	2	2	2
39	1	1	1	1	1	1	1	1	1	2	1	1	2	2	1	2	2	2	1	2
40	1	1	1	1	1	1	1	1	2	2	1	2	2	2	1	2	2	2	2	2
41	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
42	1	1	1	1	2	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
43	1	1	1	1	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2
44	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
45	1	1	1	1	1	2	1	2	2	2	1	2	2	2	2	2	2	2	2	2
46	1	1	1	1	1	2	1	2	2	2	2	2	2	2	2	2	2	2	2	2
47	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
48	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
49	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
50	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2

Gambar 11 Hasil klasifikasi *Linear Kernel* tanpa deteksi tepi

Citra 1 sampai 25 pada Gambar 11 merupakan citra bercak daun, sedangkan citra 26 sampai 50 merupakan citra daun sehat. Hasil yang seharusnya didapatkan pada tahap ini yaitu pada citra 1 sampai 25 mendapatkan keluaran angka 1 dan citra 26 sampai 50 mendapatkan keluaran angka 2. Pada Gambar 4.13 menunjukkan hasil klasifikasi Linear tanpa deteksi tepi. Kesalahan paling banyak terdapat pada sudut 0° dengan jarak 1 dan yang paling sedikit kesalahan yaitu pada sudut 135° dengan jarak 5.

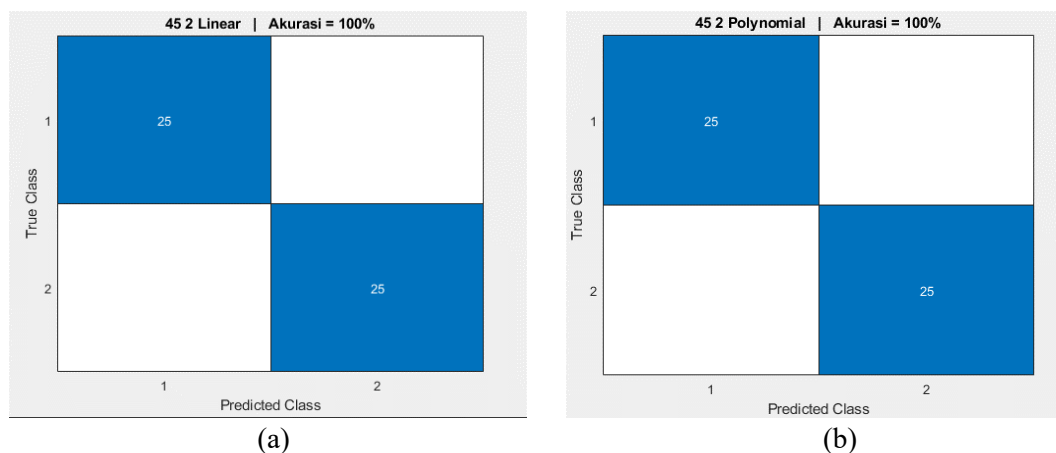
3.6 Perhitungan Performa


Perbandingan rata-rata akurasi dari *Linear Kernel* dan *Non-linear Kernel (Polynomial)* dapat dilihat pada Gambar 12.



Gambar 12 Grafik perbandingan rata-rata akurasi *Linear Kernel* dan *Non-linear Kernel*

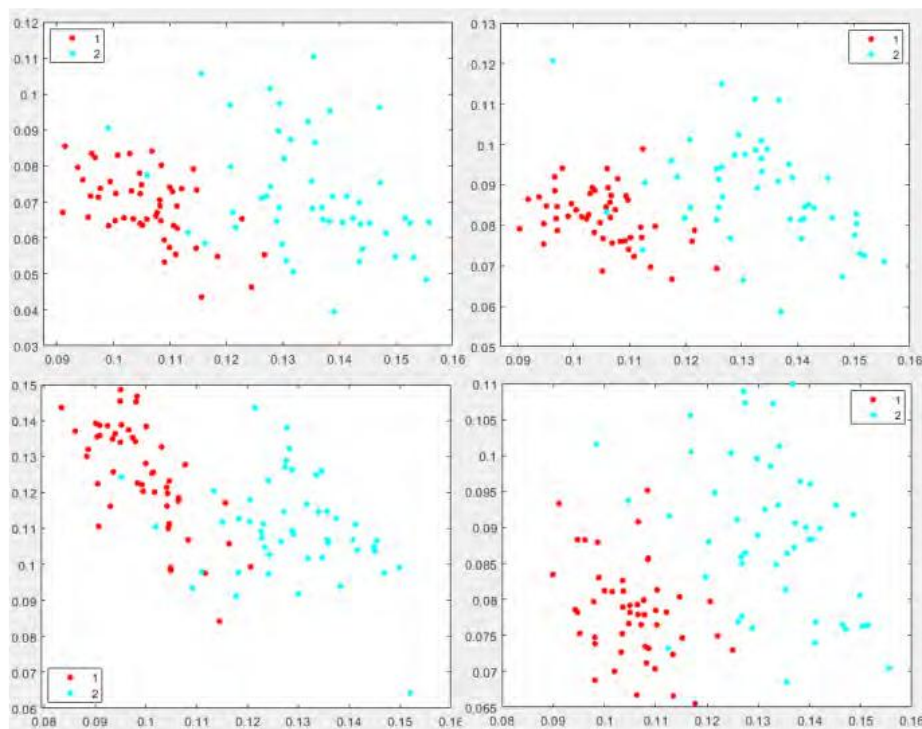
Dari hasil yang diperoleh didapatkan bahwa *Non-linear Kernel (Polynomial)* mendapatkan rata-rata akurasi yang lebih tinggi di semua data yaitu dengan rata-rata akurasi 82,6% dibandingkan dengan *Linear Kernel* dengan rata-rata akurasi 78,2%. Sehingga dapat diambil kesimpulan bahwa *Non-linear Kernel (Polynomial)* lebih baik dibandingkan dengan *Linear Kernel*.





Gambar 13 *Confusion Matrix Linear* (a) dan *Confusion Matrix Polynomial* (b) *Kernel* akurasi tertinggi, *Confusion Matrix Linear Kernel* (c) dan *Polynomial Kernel* (d) akurasi terendah

Confusion Matrix dari SVM Linear Kernel dengan akurasi tertinggi ditampilkan pada Gambar 13a, yaitu mencapai 100%. Hasil ini diperoleh melalui kombinasi Linear Kernel dan deteksi tepi Laplacian of Gaussian (LoG) di hampir semua jarak dan sudut, kecuali pada jarak 1 dan 2. Gambar 13b menunjukkan *Confusion Matrix* dari SVM Polynomial Kernel yang juga mencapai akurasi tertinggi sebesar 100% dengan konfigurasi serupa, yakni menggunakan deteksi tepi LoG di hampir seluruh kombinasi jarak dan sudut, kecuali jarak 1 dan 2. Sementara itu, Gambar 13c memperlihatkan *Confusion Matrix* dari SVM Linear Kernel dengan akurasi terendah, hanya sebesar 36%. Hasil ini diperoleh dari penggunaan deteksi tepi Roberts pada sudut 135° dan jarak 1, di mana kesalahan klasifikasi terbesar terjadi saat daun sehat terdeteksi sebagai bercak daun. Gambar 13d menunjukkan kondisi serupa pada SVM Polynomial Kernel, yang juga mencatat akurasi terendah sebesar 36% dengan konfigurasi deteksi tepi Roberts pada sudut dan jarak yang sama. Kesalahan klasifikasi paling dominan tetap terjadi pada identifikasi daun sehat yang keliru diklasifikasikan sebagai daun bercak.



Gambar 13 Persebaran data

Berdasarkan hasil penelitian yang ditunjukkan pada Gambar 6 terlihat bahwa persebaran data tidak dapat diklasifikasikan secara linier, karena tidak memungkinkan untuk menarik garis lurus yang memisahkan dua kelas. Oleh karena itu, pendekatan klasifikasi non-linier menjadi pilihan yang paling tepat untuk penelitian ini. Akurasi yang dicapai pun sangat tinggi, yakni mencapai 100%, melebihi penelitian sebelumnya. Peningkatan ini dipengaruhi oleh beberapa faktor, antara lain: kualitas citra hasil akuisisi yang baik (tidak buram atau rusak), segmentasi citra yang akurat tanpa objek terpotong, serta keberhasilan proses segmentasi yang mencapai 100%. Selain itu, proses deteksi tepi juga memberikan kontribusi besar terhadap hasil klasifikasi. Pada penelitian ini dilakukan percobaan dengan dan tanpa deteksi tepi, dan terbukti bahwa penggunaan deteksi tepi—khususnya metode *Laplace of Gaussian* (LoG)—meningkatkan akurasi secara signifikan dibandingkan tanpa deteksi tepi, yang hanya menghasilkan akurasi sekitar 90%.

Meskipun hasil citra deteksi tepi menggunakan LoG tampak sulit dibedakan secara visual antara bercak daun dan daun sehat, fitur yang diekstraksi menggunakan metode GLCM menunjukkan perbedaan nilai yang cukup signifikan. Perbedaan inilah yang memungkinkan sistem untuk melakukan klasifikasi dengan sangat baik. Dengan demikian, dapat disimpulkan bahwa proses segmentasi dan deteksi tepi, khususnya dengan metode LoG, sangat menentukan tingkat akurasi klasifikasi. Oleh karena itu, pendekatan klasifikasi yang paling tepat untuk mendeteksi penyakit bercak daun *Alternaria sp.* pada tanaman terung adalah menggunakan metode SVM dengan Kernel Linear maupun Polynomial, disertai deteksi tepi *Laplace of Gaussian* (LoG).

4. KESIMPULAN

Penelitian ini membuktikan bahwa metode berbasis *computer vision* dapat secara efektif digunakan untuk mengidentifikasi penyakit bercak daun pada tanaman terung melalui kombinasi ekstraksi fitur tekstur menggunakan *Gray Level Co-Occurrence Matrix* (GLCM) dan klasifikasi berbasis *Support Vector Machine* (SVM). Proses segmentasi citra yang akurat terbukti sangat krusial dalam keberhasilan sistem, dengan deteksi tepi menggunakan *Laplace of Gaussian* (LoG) menghasilkan segmentasi terbaik. Hasil klasifikasi menunjukkan bahwa SVM dengan Polynomial Kernel memberikan kinerja lebih baik daripada Linear Kernel, dengan rata-rata akurasi mencapai 82,6%, dan akurasi tertinggi sebesar 100% pada konfigurasi parameter GLCM tertentu. Hal ini menunjukkan bahwa pemilihan parameter sudut dan jarak dalam GLCM memiliki pengaruh signifikan terhadap efektivitas klasifikasi. Secara keseluruhan, pendekatan ini menunjukkan potensi besar dalam mendukung sistem deteksi dini penyakit tanaman secara otomatis, akurat, dan efisien.

5. SARAN

Untuk pengembangan penelitian selanjutnya, disarankan agar proses akuisisi citra dilakukan dengan kontrol pencahayaan yang lebih konsisten untuk menghindari bayangan dan noise, yang dapat memengaruhi akurasi segmentasi. Selain itu, eksplorasi terhadap metode segmentasi yang lebih adaptif dan penggunaan teknik *feature fusion* dengan kombinasi fitur warna atau morfologi dapat meningkatkan performa sistem secara keseluruhan. Integrasi pendekatan deep learning juga layak dipertimbangkan sebagai pembanding atau alternatif dalam mengatasi keterbatasan klasifikasi berbasis fitur klasik, khususnya dalam pengolahan citra tanaman yang lebih kompleks dan bervariasi di kondisi nyata lapangan.

UCAPAN TERIMA KASIH

Terima kasih yang sebesar-besarnya kepada kedua dosen pembimbing, Bapak Andika Setiawan, S.Kom., M.Cs. dan Bapak Rahman Indra Kesuma, S.Kom., M.Cs., atas bimbingan,

arahan, dan motivasi yang telah diberikan selama proses penyusunan penelitian ini hingga selesai. Penulis juga mengucapkan terima kasih kepada Program Studi Teknik Informatika, Jurusan Teknologi Produksi dan Industri, Institut Teknologi Sumatera, Lampung Selatan, atas dukungan, fasilitas, dan kesempatan yang telah diberikan sehingga penelitian ini dapat terlaksana dengan baik. Semoga ilmu, waktu, dan perhatian yang telah diberikan membawa manfaat dan menjadi amal kebaikan bagi semua pihak yang terlibat.

DAFTAR PUSTAKA

- [1] A. D. Kalifia, L. E. Astrianty, F. I. Sanjaya, and A. Pramudwiatmoko, "Empowering Digital Parenting through Web-Based Admission System and Technology Literacy Training for Families in Early Childhood Education," *MEKONGGA J. Pengabd. Masy.*, vol. 2, no. 1, pp. 30–38, 2025. <https://doi.org/10.69616/mekongga.v2i1.218>
- [2] K. Ayesha, "Gaya hidup dalam mengonsumsi sayur dan buah serta tingkat kecukupan gizi anak usia sekolah dasar di Kota Metro," 2019. <https://doi.org/10.23960/jiia.v8i3.4441>
- [3] M. Manalu, "Sistem Pakar Diagnosa Penyakit Tanaman Terong Berbasis Web Dengan Metode Dempster Shafer," *JITA (Journal Inf. Technol. Accounting)*, vol. 5, no. 2, pp. 15–27, 2022.
- [4] V. Maulidia, A. Agustinur, P. M. Sari, S. F. Lizmah, and I. Subandar, "Identifikasi Penyakit Pada Tanaman Terong (*Solanum melongena* L.) di Desa Gunung Kleng Kecamatan Meureubo Kabupaten Aceh Barat," *J. Agrotek Lestari*, vol. 9, no. 1, pp. 32–36, 2023. <https://doi.org/10.35308/jal.v9i1.7834>
- [5] T. Guo-yin, Y. Zhi-ling, Y. Zhi-lin, and Z. Shou-an, "Morphological, molecular and pathogenic characterization of *Alternaria longipes*, the fungal pathogen causing leaf spot on *Atractylodes macrocephala*," *Afr. J. Microbiol. Res.*, vol. 7, no. 21, pp. 2589–2595, 2013. <https://doi.org/10.5897/AJMR12.2091>
- [6] E. T. Suciando and D. M. Abbas, "Jenis, frekuensi kemunculan, dan persentase penyakit cendawan pada tanaman sayuran," *Maj. Ilm. Biol. Biosf. A Sci. J.*, vol. 36, no. 1, pp. 1–9, 2019.
- [7] L. P. Aji, "A Dempster-Shafer Approach for Uncertainty Management in Diagnosing Eye Diseases," *Media Comput. Sci.*, vol. 1, no. 2, pp. 77–90, 2024, doi: 10.69616/mcs.v1i2.200. <https://doi.org/10.69616/mcs.v1i2.200>
- [8] Z. K. Salsabila, N. P. T. Prakisyia, and F. Liantoni, "Deep Learning Architectures for Waste Detection: A Systematic Literature Review," *J. Media Inf. Teknol.*, vol. 2, no. 1, pp. 41–52, 2025. <https://doi.org/10.69616/mit.v2i1.213>
- [9] I. P. Sari, B. Hidayat, and R. D. Atmaja, "Perancangan dan Simulasi Deteksi Penyakit Tanaman Jagung Berbasis Pengolahan Citra Digital Menggunakan Metode Color Moments dan GLCM," *Pros. SENIATI*, vol. 2, no. 2, pp. 215-B, 2016.
- [10] N. Z. Kurniawan, S. T. Rasmana, and Y. Triwidyastuti, "Identifikasi Jenis Penyakit Daun Tembakau Menggunakan Metode Gray Level Co-Occurrence Matrix (GLCM) Dan Support Vector Machine (SVM)," *J. JCONES*, vol. 5, no. 1, pp. 163–172, 2016.
- [11] P. U. Rakhmawati, Y. M. Pranoto, and E. Setyati, "Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur Dan Fitur Warna Menggunakan Support Vector Machine," in *Seminar Nasional Teknologi dan Rekayasa (SENTRA)*, 2018, pp. 1–8.
- [12] K. Ummah, N. Nafiâ, and M. Masruroh, "IDENTIFIKASI PENYAKIT DAUN JAGUNG BERDASARKAN TEKSTUR DENGAN K-NN," *Musamus J. Technol. Inf.*, vol. 2, no. 01, pp. 1–4, 2019. <https://doi.org/10.35724/mjti.v2i1.2419>
- [13] M. Astiningrum, P. P. Arhandi, and N. A. Ariditya, "Identifikasi penyakit pada daun tomat berdasarkan fitur warna dan tekstur," *J. Inform. Polinema*, vol. 6, no. 2, pp. 47–50, 2020. <https://doi.org/10.33795/jip.v6i2.320>
- [14] M. Misda, D. Fitriyanti, and Y. Marsuni, "Uji Kemampuan Serbuk Daun Jambu Biji (*Psidium guajava* L.) dalam Mengendalikan Penyakit Antraknosa pada Tanaman Terong

- (*Solanum melongena* L.)” *J. Prot. Tanam. Trop.*, vol. 6, no. 1, pp. 598–605, 2023. <https://doi.org/10.20527/jpvt.v6i1.1696>
- [15] F. R. Haria and I. R. Harahap, “ANALYSIS OF LEAF SPOT DISEASE SEVERITY (*Alternaria* sp.) ON EGGPLANT PLANTS (*Solanum melongena* L.): ANALISIS KEPARAHAN PENYAKIT BERCAK DAUN (*Alternaria* sp.) PADA TANAMAN TERUNG (*Solanum melongena* L.)” *UPMI Proceeding Ser.*, vol. 1, no. 01, pp. 46–57, 2023.
- [16] M. Orisa and T. Hidayat, “Analisis Teknik Segmentasi Pada Pengolahan Citra,” *J. Mnemon.*, vol. 2, no. 2, pp. 9–13, 2019. <https://doi.org/10.36040/mnemonic.v2i2.84>.



© 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>).