

IDENTIFIKASI PENYAKIT DAUN TANAMAN CABAI MERAH DENGAN EKSTRAKSI FITUR DAN KLASIFIKASI SUPPORT VECTOR MACHINE

Nisa'ul Hafidhoh

Jurusan Teknik, Politeknik Negeri Madiun, Jl. Serayu no 84 Madiun

ABSTRAK

Salah satu tanaman pangan dengan permintaan tinggi adalah tanaman cabai merah. Namun, cabai merupakan tanaman yang rentan dalam proses budidaya. Penyakit patogen sering menyerang bagian vital tanaman seperti daun, faktor ini membuat produksi cabai menurun. Ditambah dengan kurangnya pemahaman tentang penyebaran penyakit hanya membuat kualitas tanaman cabai semakin menurun. Pada penelitian ini, identifikasi penyakit daun menggunakan metode Gray Level Co-Occurrence Matrix (GLCM) untuk mengekstrak fitur citra. Hasil ekstraksi fitur diklasifikasikan berdasarkan kelas penyakit daun menggunakan metode Support Vector Machine (SVM) dengan fungsi kernel. Pengujian penelitian ini menggunakan citra uji yang telah disiapkan sebelumnya, dan dihitung dengan GLCM menggunakan jarak piksel $d = 1$ sampai 5 dibantu dengan fungsi kernel gaussian dan polinomial. Setelah dilakukan perhitungan ekstraksi ciri dan klasifikasi, didapatkan hasil bahwa akurasi tertinggi berada pada piksel $d = 1$ jarak dengan akurasi fungsi polinomial 83%.

Kata kunci: Gray Level Co-Occurrence Matrix, klasifikasi, penyakit daun, Support Vector Machine, tanaman cabai

PENDAHULUAN

Tanaman cabai merah (*Capsicum annum L*) adalah salah satu komoditas unggulan di Indonesia. Jumlah permintaan cabai di pasaran pun terus meningkat dan cabai juga memiliki harga jual yang cukup tinggi. Oleh karena itu, selain petani cabai, banyak juga masyarakat yang melakukan budidaya cabai. Berdasarkan data dari Badan Pusat Statistik (BPS), jumlah produksi cabai di Indonesia mencapai 1,39 juta ton pada tahun 2021. Akan tetapi, jumlah tersebut turun 8,09% jika dibandingkan pada tahun 2020 sebesar 1,5 juta ton. Penurunan produksi cabai ini adalah pertama kalinya dalam satu dekade terakhir (Rizaty, 2022).

Adapun turunnya produksi cabai dapat diakibatkan oleh serangan hama yang mengakibatkan para petani cabai gagal panen (Cahyono, 2022). Faktor lainnya adalah perubahan iklim dan cuaca yang tidak menentu juga dapat menjadi sebab awal munculnya penyakit patogen pada tanaman. Organisme penyerang tanaman seperti penyakit patogen, hama, dan gulma banyak menyerang bagian vital dalam pertumbuhan tanaman cabai khususnya pada bagian daun (Hafidhoh, dkk, 2019). Bila tanaman sudah terjangkit penyakit pada bagian vital tersebut akan membusuk dan mati secara berkala. Jika hama maupun penyakit yang dapat menyerang tanaman cabai tersebut tidak segera ditangani dapat merusak tanaman dan merugikan petani. Beberapa cara dapat dilakukan untuk mencegah atau mengurangi penyakit pada tanaman cabai antara lain menggunakan pestisida, fungisida maupun obat kimia lainnya. Tentu saja penanganan tersebut harus disesuaikan dengan penyebab penyakit pada tanaman cabai, karena penanganan yang tidak tepat dapat menurunkan kualitas tanaman. Oleh karena itu, diperlukan proses untuk mengidentifikasi dan klasifikasi jenis penyakit tanaman cabai agar penanganan yang diberikan pun bisa sesuai.


Berbagai penelitian untuk identifikasi maupun diagnosis penyakit tanaman cabai juga telah dikembangkan. Salah satunya adalah diagnosis penyakit cabai dengan *Forward Chaining – Demphster Shafer*, perangkian penyakit didapat dari 18 gejala penyakit yang dimasukkan pengguna secara manual (Wijaya, 2018). Wibowo (2017) menggunakan *computer vision* untuk deteksi penyakit dan hama tanaman cabai yang dilihat dari buah maupun daun cabai. Pada penelitian

ini akan digunakan daun sebagai citra dari tanaman cabai yang terjangkit untuk dilakukan identifikasi dan klasifikasi jenis penyakit. Rekognisi citra membutuhkan dua proses utama yaitu ekstraksi ciri dan klasifikasi objek. Proses ekstraksi ciri dilakukan dengan identifikasi fitur tekstur berdasarkan skala keabuan menggunakan algoritma *Gray Level Co-Occurrence Matrix* (GLCM). Ekstraksi fitur GLCM adalah salah satu metode yang cukup efektif untuk identifikasi citra melalui ekstraksi ciri (Nafisah, dkk, 2021). Ekstraksi fitur GLCM dengan 4 sudut dapat menghasilkan data valid hingga 80% (Kusanti dan Haris, 2018). Tujuan dari penggunaan algoritma GLCM adalah menghasilkan set fitur dari daun citra tanaman cabai. Set fitur tersebut digunakan pada proses pembelajaran untuk data latih maupun data uji untuk proses klasifikasi objek. Proses klasifikasi untuk menentukan suatu objek masuk ke dalam kelas atau kategori tertentu pada penelitian ini menggunakan metode *Support Vector Machine* (SVM). SVM mempunyai konsep usaha dalam mencari hyperplane terbaik dimana fungsi tersebut digunakan sebagai pemisah satu atau lebih kelas. SVM dikenal sebagai salah satu metode klasifikasi dengan nilai akurasi yang cukup tinggi. Beberapa penelitian awal menunjukkan hasil klasifikasi menggunakan SVM mencapai 94,4% (Puspitasari, dkk, 2018), penggunaan kernel fungsi quadratic SVM juga mencapai 96,2% (Ritonga & Purwaningsih, 2018).

METODE

Gray Level Co-Occurrence Matrix

Gray Level Co-Occurrence Matrix (GLCM) adalah salah satu metode analisis tekstur citra yang diperkenalkan oleh haralick pada tahun 1970-an. Secara statistik, suatu objek dapat dilihat dari tekstur objek tersebut, yaitu tekstur objek dihitung dari dasar distribusi statistik antara dua pixel dengan hubungan posisi spasial atau sering disebut intensitas pixel sesuai dengan spasial derajat keabuan. Konsep sederhana metode algoritma GLCM adalah dapat menghitung berbagai macam piksel dengan intensitas i , dan adanya kesamaan dengan pixel j , pada jarak d dan orientasi dari sudut θ . Pada umumnya, GLCM digunakan dalam 4 orientasi sudut tertentu, yaitu sudut 0° , 45° , 90° , dan 135° seperti pada Gambar 1 (Mukherjee, dkk, 2016).



Gambar 19. Perbedaan Orientasi Sudut

Posisi spasial tiap block piksel selalu berhubungan dengan jarak dan sudut. Matriks citra akan dijumlahkan dengan piksel tetangga, proses ini disebut dengan *Co-Occurrence Matrix*. Selanjutnya proses simetrisasi akan menjumlahkan matriks hasil *Co-Occurrence* dengan dirinya sendiri, agar matriks dapat simetris. Proses ini berlanjut sampai GLCM mendapatkan hasil normalisasi. Setelah mendapatkan hasil normalisasi matriks akan dijadikan input pengukuran probabilistik yang merepresentasikan fitur tekstur. Ada empat parameter tekstur yang umum digunakan dalam penggunaan metode GLCM (Jundullah, 2016), yaitu sebagai berikut [6] :

1. Contrast sebagai parameter dalam ketergantungan linear terhadap label keabuan pixel tetangga.

$$\sum_{i,j} |i - j|^2 p(i, j) \quad (1)$$

2. Correlation sebagai parameter terhadap ketergantungan linier derajat keabuan dari tiap piksel yang bertetangga pada objek citra.

$$\sum_i \sum_j P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (2)$$

3. Energy sebagai parameter terhadap ukuran konsentrasi dari pasangan intensitas dalam matriks.


$$\sum_{i,j} p(i,j)^2 \quad (3)$$

4. Homogeneity sebagai parameter terhadap macam varian dari intensitas dalam objek citra. Kehomogenan dapat menilai kekasaran bidang objek citra

$$\sum_{i,j} \frac{p(i,j)}{1 + |i - j|} \quad (4)$$

Support Vector Machine

Support vector machine (SVM) adalah model dari *Supervised Learning*, salah satu metode yang sering dipakai dalam klasifikasi analisis data dan pengenalan pola. SVM diperkenalkan oleh Vapnik pada tahun 1992. Konsep SVM adalah usaha untuk menemukan solusi sebagai fungsi pemisah optimal yang disebut *hyperplane* pemisah terbaik dari dua set data dan kelas yang berbeda. Suatu pola sebagai representatif anggota untuk dua buah class, yaitu class +1 dan class -1. *Hyperplane* pemisah terbaik diperlukan untuk memisahkan pola sesuai dengan class dengan mengukur margin *hyperplane* tersebut (Ritonga & Purwaningsih, 2018).

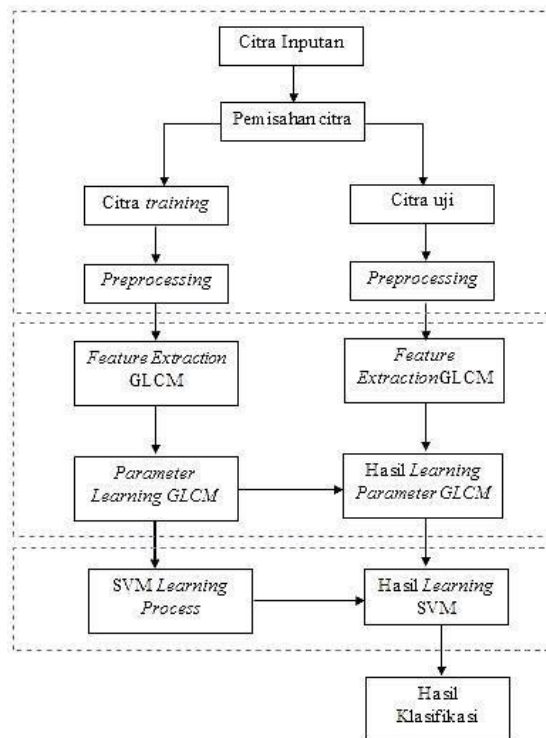


Gambar 20. Contoh Dua Set Kelas ber-Hyperplane

Gambar 2 menunjukkan bahwa garis solid merupakan margin yang digunakan secara maksimal sebagai *hyperplane* pemisah terbaik yang terletak tepat diantara dua class, dan pola yang berada dalam lingkaran hitam disebut dengan *support vector*. Dari gambaran tersebut memperlihatkan metode SVM bekerja untuk mencari lokasi *hyperplane* pemisah terbaik untuk selanjutnya dijadikan sebagai proses *learning* pada metode ini. Konsep dasar dari metode SVM adalah *linear classifier* yang selanjutnya dikembangkan kembali agar dapat bekerja dalam problem non-linear, dibantu dengan konsep *kernel trick* untuk memetakan data ke ruang kerja berdimensi tinggi. Konsep *kernel trick* ini memberikan kemudahan dalam proses *learning* pada metode SVM, sehingga hanya perlu mengetahui fungsi Kernel tanpa harus mengubah secara manual data non-linear tersebut.

Metode Klasifikasi Citra

Metode klasifikasi citra digunakan untuk memproses citra agar dapat teridentifikasi sesuai dengan kelas yang sudah diberikan. Proses klasifikasi citra pada penelitian ini menggunakan metode GLCM dan SVM yang dapat dilihat dalam diagram proses pada Gambar 3.




Gambar 21. Diagram Proses Klasifikasi Citra

Proses klasifikasi citra digambarkan melalui Gambar 3 terdiri dari beberapa tahapan berikut :

1. Tahap awal untuk menganalisis data dimulai dengan memasukkan citra yang sesuai dengan objek penelitian, citra yang dipakai sebelumnya sudah disesuaikan dengan ukuran 95x95 pixel. Citra tersebut selanjutnya dibagi menjadi dua kelompok yaitu citra data latih dan citra data uji sebanyak 65% data latih – 35% data uji.
2. Kedua kelompok citra tersebut selanjutnya masuk tahap *preprocessing* dengan proses penambahan warna oleh HSV pada fungsi MATLAB *rgb2hsv* dan *grayscale* dengan mengubah setiap piksel pada RGB citra menjadi keabuan dengan fungsi pada MATLAB yaitu *hsv2gray*.
3. Tahap berikutnya yaitu kedua kelompok citra yang sudah melalui *preprocessing* akan melalui proses ekstraksi fitur GLCM dengan menggunakan citra yang sudah diberikan derajat keabuan.
4. Tahap akhir setelah mendapatkan nilai dari hasil ekstraksi fitur adalah masuk ke proses klasifikasi, untuk mengelompokkan citra sesuai dengan label jenis penyakit. Citra data latih dipakai sebagai pembelajaran pada klasifikasi untuk cek kelinearan, penambahan fungsi kernel, dan pengelompokkan kelas. Hasil dari pembelajaran dijadikan acuan untuk menguji citra data uji agar dapat mengidentifikasi jenis yang sesuai.

HASIL DAN PEMBAHASAN

Pada penelitian ini menggunakan dataset sebanyak 90 citra yang akan dibagi menjadi dua data pengolahan yaitu sebanyak 30 citra data latih dari dua jenis penyakit dan 15 citra data uji dari dua jenis penyakit, maka total dari pembagian data yaitu sebanyak 60 citra data latih dan 30 citra data uji. Kedua data pengolahan memiliki ukuran yang sama yaitu 95 x 95 piksel, dan dilanjutkan ke tahap *preprocessing* seperti terlihat pada Gambar 4.



Gambar 22. Hasil *preprocessing* (a) Citra asli (b) Citra HSV (c) Citra *Grayscale*

Proses Ekstraksi Fitur

Tahap selanjutnya yaitu proses ekstraksi fitur, dalam proses ini semua citra baik data latih maupun data uji yang sudah diberi derajat keabuan akan dilakukan perhitungan ekstraksi fitur dari tiap citranya. Seperti yang sudah di bahas pada bab sebelumnya, proses kalkulasi dari GLCM ini menghitung matrik dari tiap citra dengan jarak piksel yang ditentukan dan orientasi dari keempat sudut, serta keempat parameter yaitu *Contrast*, *Correlation*, *Energy*, dan *Homogeneity*. Dari kalkulasi yang dilakukan maka hasil kalkulasi ekstraksi fitur dapat dilihat pada Tabel 1.

Tabel 1. Hasil Kalkulasi Ekstraksi Fitur GLCM Menggunakan Data Latih

Ci tr a L ati h	Orientasi Sudut				Ci tr a L ati h	Orientasi Sudut			
	Contrast	Correlat ion	Energy	Homogen eity		Cont rast	Correlat ion	Ener gy	Homogen eity
1	0,3022	0,8610	0,1775	0,8936	31	0,0970	0,8512	0,4473	0,9531
2	0,3290	0,8476	0,1876	0,9005	32	0,1345	0,7801	0,3942	0,9401
3	0,0956	0,9576	0,3102	0,9543	33	0,1316	0,7520	0,5673	0,9377
4	0,1997	0,8987	0,2273	0,9207	34	0,2004	0,8096	0,3211	0,9340
5	0,1899	0,7648	0,3616	0,9083	35	0,0544	0,9084	0,4435	0,9728
6	0,1254	0,9373	0,2311	0,9393	36	0,1423	0,7744	0,4246	0,9404
7	0,1320	0,9402	0,2023	0,9341	37	0,0734	0,9367	0,3250	0,9633
8	0,1914	0,8772	0,3088	0,9150	38	0,0923	0,7114	0,6251	0,9549
9	0,1734	0,8445	0,3149	0,9187	39	0,1100	0,8303	0,4228	0,9450
10	0,1122	0,9284	0,2490	0,9441	40	0,1442	0,9738	0,2104	0,9386
11	0,1254	0,9373	0,2311	0,9393	41	0,1432	0,9046	0,2988	0,9329
12	0,1249	0,9178	0,3228	0,9396	42	0,0482	0,8984	0,6625	0,9831
13	0,0981	0,9478	0,3215	0,9515	43	0,1378	0,7107	0,4575	0,9311
14	0,0758	0,9417	0,4892	0,9623	44	0,1133	0,7889	0,4932	0,9456
15	0,1686	0,8505	0,2897	0,9289	45	0,1330	0,7471	0,3927	0,9336
16	0,2468	0,8513	0,3644	0,9064	46	0,2671	0,5974	0,3420	0,8749
17	0,1772	0,8544	0,4480	0,9347	47	0,1638	0,7327	0,4283	0,9264
18	0,1627	0,9164	0,2220	0,9191	48	0,2693	0,4827	0,4763	0,8912

19	0,1914	0,8772	0,3088	0,9150	49	0,1449	0,8838	0,2996	0,9412
20	0,3022	0,8610	0,1775	0,8936	50	0,4319	0,7947	0,1602	0,8541
21	0,1252	0,8023	0,4702	0,9501	51	0,1060	0,8174	0,5081	0,9479
22	0,1705	0,7184	0,3616	0,9244	52	0,2516	0,8704	0,1848	0,8961
23	0,1772	0,8544	0,4480	0,9347	53	0,2625	0,7557	0,2587	0,8857
24	0,1601	0,7803	0,4102	0,9312	54	0,2872	0,6618	0,3093	0,8813
25	0,3271	0,8300	0,1837	0,8906	55	0,1442	0,9738	0,2104	0,9386
26	0,3084	0,6989	0,2562	0,8886	56	0,0757	0,9439	0,2918	0,9652
27	0,2025	0,8331	0,2400	0,9005	57	0,1995	0,8630	0,2560	0,9138
28	0,1096	0,6963	0,6110	0,9488	58	0,1100	0,8303	0,4228	0,9450
29	0,1068	0,8033	0,6034	0,9667	59	0,0297	0,8755	0,7750	0,9852
30	0,1260	0,7474	0,3931	0,9370	60	0,1320	0,9402	0,2023	0,9341

Tabel 2. Hasil Kalkulasi Ekstraksi Fitur GLCM Menggunakan Data Uji

Ci tra La tih	Orientasi sudut				Ci tr a L ati h	Orientasi sudut			
	Cont rast	Correlat ion	Ener gy	Homogen eity		Cont rast	Correlat ion	Ener gy	Homogene ity
1	0,2468	0,8513	0,3644	0,9064	16	0,2872	0,6618	0,3093	0,8813
2	0,0956	0,9576	0,3102	0,9543	17	0,2025	0,8331	0,2400	0,9005
3	0,1122	0,9284	0,2490	0,9441	18	0,2617	0,6727	0,3061	0,8779
4	0,1914	0,8772	0,3088	0,9150	19	0,0533	0,9082	0,4491	0,9733
5	0,0731	0,9437	0,4436	0,9641	20	0,2830	0,8655	0,2068	0,9104
6	0,1254	0,9373	0,2311	0,9393	21	0,1133	0,7889	0,4932	0,9456
7	0,1148	0,9260	0,2746	0,9426	22	0,3856	0,6471	0,2543	0,8481
8	0,2768	0,7489	0,3250	0,9010	2	0,0802	0,8889	0,3876	0,9599

					3				
9	0,2004	0,8096	0,3211	0,9340	2	0,1076	0,9347	0,2625	0,9484
					4				
10	0,0715	0,7273	0,7405	0,9691	2	0,1289	0,6513	0,6401	0,9482
					5				
11	0,3022	0,8610	0,1775	0,8936	2	0,1449	0,8838	0,2996	0,9412
					6				
12	0,2175	0,8613	0,2301	0,9204	2	0,0481	0,7314	0,7835	0,9760
					7				
13	0,2430	0,6903	0,3123	0,8944	2	0,0944	0,7963	0,5363	0,9555
					8				
14	0,1772	0,8544	0,4480	0,9347	2	0,1206	0,8406	0,4386	0,9488
					9				
15	0,0790	0,9530	0,3536	0,9608	3	0,1320	0,9402	0,2023	0,9341
					0				

Tabel 1 dan tabel 2 diatas merupakan hasil kalkulasi Mean dari 4 orientasi sudut yaitu 0 , 45, 90 , dan 135 derajat serta Parameter pada GLCM menggunakan kedua dataset yaitu data latih dan data uji. Kedua tabel diatas pun menggunakan contoh jarak piksel $d = 1$, sedangkan pada data latih aslinya di hitung jarak piksel dari 1 sampai dengan 5. Dari hasil dari kedua kalkulasi tersebut akan di proses lebih lanjut ke tahap Klasifikasi.

Proses Klasifikasi

Setelah mendapatkan hasil kalkulasi *Mean* dari proses perhitungan ekstraksi fitur GLCM dan parameternya, maka dilanjutkan pada tahap klasifikasi menggunakan *Support Vector Machine* (SVM). Sebelum melakukan klasifikasi diperlukan proses kelinearan, proses ini diperlukan untuk melihat apakah data yang diproses sudah bersifat linear atau non – linear. Hal ini pun berkaitan dengan diperlukannya pemakaian fungsi kernel. Dari data acuan yang dipakai adalah data perhitungan *mean* pada tabel 1 menunjukkan bahwa data yang diolah merupakan data non-linier. Hal ini berkaitan dengan proses selanjutnya yaitu proses klasifikasi dengan bantuan fungsi kernel, penggunaan konsep *kernel trick* ini memberikan kemudahan dalam proses *Learning* pada metode SVM, sehingga kita hanya perlu mengetahui fungsi Kernel tanpa harus mengubah secara manual data non-linear tersebut.

Kernel yang digunakan pada penelitian ini yaitu kernel Gaussian dan Polynomial. Penelitian ini menggunakan dua kernel dengan tujuan membandingkan fungsi kernel manakah yang lebih akurat dalam klasifikasi sesuai dengan kelasnya, dan kedua hasil fungsi kernel ini pun nantinya akan menjadi pembelajaran pada data training. Berikut merupakan tabel data latih yang sudah mempunyai label untuk kedua fungsi kernel.

Pada tabel 3 merupakan pelabelan data latih menggunakan jarak piksel $d = 1$, sedangkan pada data latih aslinya di hitung jarak piksel dari 1 sampai dengan 5. Setelah mendapatkan pembelajaran pada data latih menggunakan jarak piksel $d = 1$ sampai dengan 5 di kedua fungsi kernelnya, maka klasifikasi data uji dapat dilakukan. Pengujian data uji dilakukan dengan tahap yang sama dengan data latih dan menghasilkan identifikasi penyakit sesuai dengan jenis kelasnya. Terdapat dua kelas yang digunakan dalam klasifikasi penyakit tanaman cabai yaitu jenis jamur atau bakteri.

Tabel 3. Hasil Pelabelan Data Latih

C itr	Orientasi Sudut				Cl as	Ci tr	Orientasi Sudut				C la
	Contr	Correlat	Ener	Homo			Contr	Correlat	Energy	Hom	

a L at ih	ast	ion	gy	ge	s	a L ati h	ast	ion		oge	ss
1	0,3022	0,861	0,17 75	0,8936	0	31	0,097	0,8512	0,4473	0,95 31	1
2	0,329	0,8476	0,18 76	0,9005	0	32	0,134 5	0,7801	0,3942	0,94 01	1
3	0,0956	0,9576	0,31 02	0,9543	0	33	0,131 6	0,752	0,5673	0,93 77	1
4	0,1997	0,8987	0,22 73	0,9207	0	34	0,200 4	0,8096	0,3211	0,93 4	1
5	0,1899	0,7648	0,36 16	0,9083	0	35	0,054 4	0,9084	0,4435	0,97 28	1
6	0,1254	0,9373	0,23 11	0,9393	0	36	0,142 3	0,7744	0,4246	0,94 04	1
7	0,132	0,9402	0,20 23	0,9341	0	37	0,073 4	0,9367	0,325	0,96 33	1
8	0,1914	0,8772	0,30 88	0,915	0	38	0,092 3	0,7114	0,6251	0,95 49	1
9	0,1734	0,8445	0,31 49	0,9187	0	39	0,11	0,8303	0,4228	0,94 5	1
10	0,1122	0,9284	0,2 49	0,9441	0	40	0,144 2	0,9738	0,2104	0,93 86	1
11	0,1254	0,9373	0,23 11	0,9393	0	41	0,143 2	0,9046	0,2988	0,93 29	1
12	0,1249	0,9178	0,32 28	0,9396	0	42	0,048 2	0,8984	0,6625	0,98 31	1
13	0,0981	0,9478	0,32 15	0,9515	0	43	0,137 8	0,7107	0,4575	0,93 11	1
14	0,0758	0,9417	0,48 92	0,9623	0	44	0,113 3	0,7889	0,4932	0,94 56	1
15	0,1686	0,8505	0,28 97	0,9289	0	45	0,133	0,7471	0,3927	0,93 36	1
16	0,2468	0,8513	0,36 44	0,9064	0	46	0,267 1	0,5974	0,342	0,87 49	1
17	0,1772	0,8544	0,4 48	0,9347	0	47	0,163 8	0,7327	0,4283	0,92 64	1
18	0,1627	0,9164	0,2 22	0,9191	0	48	0,269 3	0,4827	0,4763	0,89 12	1
19	0,1914	0,8772	0,30 88	0,915	0	49	0,144 9	0,8838	0,2996	0,94 12	1
20	0,3022	0,861	0,17	0,8936	0	50	0,431	0,7947	0,1602	0,85	1

			75				9			41	
2 1	0,1252	0,8023	0,47 02	0,9501	0	51	0,106	0,8174	0,5081	0,94 79	1
2 2	0,1705	0,7184	0,36 16	0,9244	0	52	0,251 6	0,8704	0,1848	0,89 61	1
2 3	0,1772	0,8544	0,4 48	0,9347	0	53	0,262 5	0,7557	0,2587	0,88 57	1
2 4	0,1601	0,7803	0,41 02	0,9312	0	54	0,287 2	0,6618	0,3093	0,88 13	1
2 5	0,3271	0,83	0,18 37	0,8906	0	55	0,144 2	0,9738	0,2104	0,93 86	1
2 6	0,3084	0,6989	0,25 62	0,8886	0	56	0,075 7	0,9439	0,2918	0,96 52	1
2 7	0,2025	0,8331	0,24	0,9005	0	57	0,199 5	0,863	0,256	0,91 38	1
2 8	0,1096	0,6963	0,6 11	0,9488	0	58	0,11	0,8303	0,4228	0,94 5	1
2 9	0,1068	0,8033	0,60 34	0,9667	0	59	0,029 7	0,8755	0,775	0,98 52	1
3 0	0,126	0,7474	0,39 31	0,937	0	60	0,132	0,9402	0,2023	0,93 41	1

Setelah melakukan tahap klasifikasi data uji, maka akan menghasilkan identifikasi penyakit. Hasil identifikasi yang dilakukan dalam jarak piksel $d = 1$ sampai dengan 5 di kedua fungsi kernelnya harus dicari akurasi tertinggi. Perhitungan persentase pengujian ini menggunakan rumus akurasi no 5 untuk menghasilkan keakuratan dari masing – masing citra pada jenis objeknya. Dari penggunaan rumus akurasi maka hasil dari persentase klasifikasi data uji ini dapat dilihat pada Tabel 4.


$$Akurasi (\varphi) = \frac{\text{jumlah citra benar atau dikenali}}{\text{jumlah total citra keseluruhan}} \times 100\% \quad (5)$$

Tabel 4. Perbandingan Akurasi Klasifikasi Data Uji dengan Fungsi Kernel

Jarak Piksel	Gaussian			Jarak Piksel	Polynomial		
	Salah	Benar	Persen		Salah	Benar	Persen
1	8	22	73%	1	5	25	83%
2	10	20	67%	2	7	23	76%
3	10	20	67%	3	8	22	73%
4	8	22	73%	4	8	22	73%

5	7	23	76%	5	11	19	63%
---	---	----	-----	---	----	----	-----

Hasil dari analisis keberhasilan dapat dilihat melalui grafik yang tertera pada Gambar 5 yaitu perbandingan akurasi klasifikasi data uji dari kedua Fungsi Kernel SVM yakni Gaussian dan Polynomial. Hasil dari kernel polynomial rata - rata mempunyai tingkat akurasi data yang lebih tinggi dibanding dengan Kernel Gaussian. Dari kernel Polynomial pun piksel dengan keberhasilan akurasi tertinggi terdapat pada piksel 1. Hal ini dapat menunjukkan bahwa dengan menggunakan jarak piksel 1 pada kernel Polynomial yang paling baik dalam mengklasifikasikan citra dengan akurasi 83%.



Gambar 23. Perbandingan Akurasi Klasifikasi Data Uji dengan Fungsi Kernel

KESIMPULAN

Berdasarkan penelitian yang dilakukan maka diperoleh hasil sebagai berikut :

1. Penggunaan metode ekstraksi fitur *Gray Level Co – Occurance Matrix* (GLCM) dapat diterapkan dengan menggunakan Mean dari 4 orientasi sudut, jarak piksel $d = 1$ sampai dengan 5, dan parameter Contrast, Correlation, Energy, dan Homogeneity.
2. Klasifikasi menggunakan *Support Vector Machine* (SVM) pun dapat diterapkan dan diuji menggunakan 2 fungsi Kernel yakni Gaussian dan Polynomial.
3. Perbandingan dari varian jarak piksel dan fungsi kernel, menghasilkan akurasi tertinggi pada jarak piksel $d = 1$ menggunakan kernel Polynomial dengan hasil akurasi yang cukup tinggi hingga 83% untuk total kedua kelas.

REFERENSI

- Cahyono, A. H. (2022). *Analisis Produksi dan Pemasaran. Usahatani Cabai Rawit Desa Lakardowo Kecamatan Jetis Kabupaten Mojokerto*. Tesis : UPN Jatim.
- Hafidhoh, N., Ningrum, N. K., Anantri N. F. (2019). Pengembangan Aplikasi Klasifikasi Penyakit Daun Tanaman Cabai Dengan Metode Prototyping. Prosiding dalam Science and Engineering National Seminar 4.

- Jundullah, A. (2016). *Analisis dan Implementasi Deteksi Citra Spam Menggunakan Gray Level Co-occurences Matrix dan Naive Bayes*. Skripsi : Universitas Telkom.
- Kusanti, J., Haris, N. A. (2018). Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut. *Jurnal Pengembangan IT, Vol 03, No 01*, 1-6.
- Mukherjee, A., Gaurav, K., Verma, A., Kumar, H., dan Thakur, R. (2016). Content Based Image Retrieval using GLCM. *International Journal of Innovative Research in Computer and Communication Engineering. Vol 4, No 11*, 20142-20149
- Nafisah, N., Adam, R. I., Carudin. (2021). Klasifikasi K-NN dalam Identifikasi Penyakit COVID-19 Menggunakan Ekstraksi Fitur GLCM. *Journal of Applied Informatics and Computing Vol 5, No 2*, 128-132
- Puspitasari. A. M., Ratnawati, D. E., Widodo, A. W. (2018). Klasifikasi Penyakit Gigi Dan Mulut Menggunakan Metode Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 2, No. 2*, 802-810
- Ritonga, A. S. dan Purwaningsih, E. S. (2018). Penerapan Metode Support Vector Machine (SVM) Dalam Klasifikasi Kualitas Pengelasan SMAW (Shield Metal Arc Welding). *Jurnal Ilmiah Edutic Vol.5, No.1*, 17-25
- Rizaty, M. A. (2022, Juli 19). *Produksi Cabai Rawit di Indonesia Turun 8,09% pada 2021 (Webpage)*. Retrieved from DataIndonesia.id : <https://dataindonesia.id/sektor-riil/detail/produksi-cabai-rawit-di-indonesia-turun-809-pada-2021>
- Wibowo, A. P. W. (2017). Penerapan Teknik Computer Vision Pada Bidang Fitopatologi Untuk Diteksi Penyakit dan Hama Tanaman Cabai. *Jurnal Pengembangan IT Vol 2, No 2*, 102-108.
- Wijaya E.H., Hidayat N., Suprpto. (2018). Diagnosis penyakit cabai dengan menggunakan metode Forward Chaining – Demphster Shafer. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer. Vol 2(12): 7202-7208*.