

Klasifikasi Penyakit Daun Kopi Robusta Menggunakan Metode SVM dengan Ekstraksi Ciri GLCM

Agus Supriyanto¹, R Rizal Isnanto², Oky Dwi Nurhayati³

¹ Departemen Teknik Elektro, Fakultas Teknik, Universitas Diponegoro, Jl. Prof. Soedarto, Tembalang, Kec. Tembalang, Semarang 50275 INDONESIA, (tel.: 024-7460057; email: agussupriyanto.elektro@gmail.com)

^{2,3} Departemen Teknik Komputer, Fakultas Teknik, Universitas Diponegoro, Jl. Prof. Soedarto, Tembalang, Kec. Tembalang, Semarang 50275 INDONESIA (tel.: 024-76480609; email: ²rizal_isnanto@yahoo.com, ³okydwin@gmail.com)

[Diterima: 20 Juli 2023, Direvisi: 12 September 2023]

Corresponding Author: Agus Supriyanto

INTISARI — Tanaman kopi merupakan sumber pendapatan bagi beberapa petani di Indonesia dan berperan penting sebagai penghasil devisa negara. Produksi tanaman kopi dapat menurun akibat serangan hama dan penyakit. Beberapa penyakit yang sering terjadi pada tanaman kopi adalah penyakit pada daun, berupa bercak daun (*Cercospora coffeicola*) dan karat daun (*Hemileia vastatrix*). Penelitian yang dilakukan bertujuan untuk mengenali jenis penyakit pada daun kopi robusta dan mengetahui hasil klasifikasi. Penerapan teknologi pengolahan citra berbasis *machine learning* menggunakan metode klasifikasi *support vector machine* (SVM) berdasarkan ekstraksi ciri *gray level co-occurrence matrix* (GLCM) menjadi solusi yang diusulkan. Prapengolahan diperlukan sebelum dilakukannya pengolahan untuk meningkatkan kualitas citra supaya mudah dianalisis. Kemudian, dilakukan segmentasi menggunakan *k-means clustering*. Proses segmentasi *k-means clustering* dengan tiga *cluster* digunakan untuk membedakan bagian yang terdampak penyakit bercak daun atau karat daun dengan bagian yang tidak terdampak penyakit. Metode GLCM digunakan sebagai ekstraksi ciri, berdasarkan fitur *angular second moment* (ASM) atau energi, kontras, korelasi, *inverse different moment* (IDM) atau homogenitas, dan entropi dengan sudut 0°, 45°, 90°, dan 135°, serta jarak antar piksel 1 sampai 3 piksel. Metode SVM digunakan sebagai klasifikasi dengan *kernel* linear, polinomial, dan *Radial Basis Function* (RBF) Gaussian. Penelitian ini menggunakan citra bercak daun dan karat daun, dengan jumlah data latih 320 citra dan data uji 80 citra. Hasil pengujian terbaik diperoleh pada kernel RBF Gaussian dengan tingkat akurasi terbaik sebesar 97,5%, presisi 95,24%, *recall* 100%, dan *F1-score* 97,56%.

KATA KUNCI — Daun Kopi Robusta, Penyakit Karat Daun, Penyakit Bercak Daun, SVM, GLCM.

I. PENDAHULUAN

Kopi merupakan jenis tanaman berbentuk pohon yang termasuk dalam keluarga *Rubiaceae* dan genus *Coffea* [1], [2]. Genus kopi memiliki sekitar seratus jenis, tetapi hanya dua dari spesies tersebut yang bernilai komersial tinggi, terutama kopi robusta dan kopi arabika. Jenis kopi lainnya hanya digunakan sebagai campuran untuk meningkatkan aroma, seperti biji kopi *excelsa* dan biji kopi *liberica* [3]. Kopi merupakan salah satu minuman yang paling banyak dikonsumsi di dunia, sehingga merupakan bahan pangan yang cukup relevan dari segi ekonomi [4].

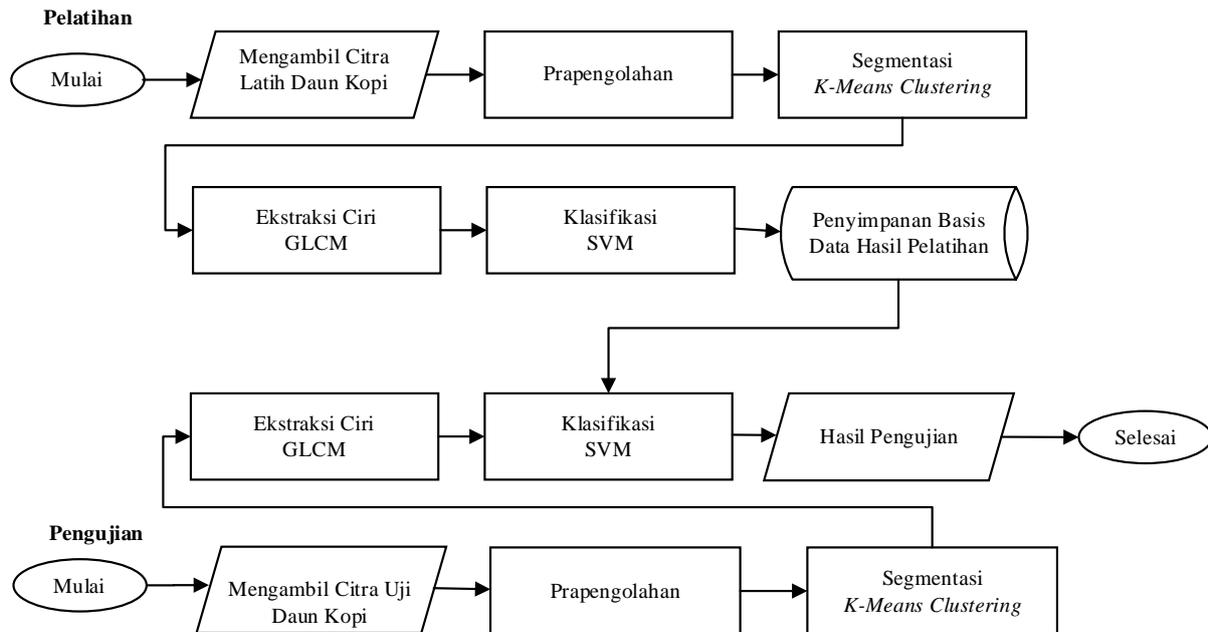
Kopi merupakan komoditas unggulan bagi perkebunan penghasil devisa negara, sumber pendapatan petani, penghasil komoditas industri, penciptaan lapangan kerja, dan pengembangan daerah. Indonesia adalah negara terbesar keenam di dunia sebagai penghasil kopi setelah Brasil, Vietnam, Kolombia, Honduras, dan India; serta negara penghasil kopi terbesar kedua di Asia Tenggara. Keenam negara tersebut mengekspor 73,7% kopi dunia, dengan rincian Brasil 29,1%, Vietnam 20,5%, Kolombia 10,5%, Honduras 5,3%, India 4,7%, dan Indonesia 3,6% [5], [6]. Produksi kopi di Indonesia menurun akibat kurangnya pengetahuan petani terhadap berbagai penyakit dan hama yang menyerang tanaman kopi.

Penyakit tanaman adalah suatu kondisi munculnya gejala ketika jaringan dan sel tanaman berhenti berfungsi secara normal sebagai akibat gangguan konstan dari patogen atau lingkungan [7]. Penyakit-penyakit yang menyerang tanaman kopi di antaranya adalah penyakit bercak daun, karat daun, penyakit busuk kopi, dan penyakit jamur upas. Penyakit bercak daun (*Cercospora coffeicola*) dan penyakit karat daun (*Hemileia vastatrix*) merupakan dua penyakit tanaman yang

menyerang daun kopi. Penyakit ini menyebabkan produktivitas kopi menjadi rendah, gagal panen, dan mengakibatkan tanaman mati. Kurangnya pengetahuan petani terhadap dampak penyakit tanaman kopi mengakibatkan kegagalan panen, sehingga merugikan dan membuat petani kopi khawatir. Penyakit bercak daun kopi yang disebabkan oleh jamur *Cercospora coffeicola* dikenal sebagai bercak mata coklat, yang tersebar luas di Indonesia dan di seluruh dunia. Bercak bulat, konsentris, coklat kemerahan atau coklat tua merupakan tanda serangan pada daun. Bercak daun dalam cuaca lembab dapat menjadi lebih besar dan dapat menyebabkan rontoknya daun [6], [8]. Jamur *Hemileia vastatrix*, yang menginfeksi genus *Coffea*, menyebabkan penyakit karat daun, yang lebih parah terjadi pada kopi arabika dan robusta [9]. Gejala penyakit karat daun dapat dilihat dengan adanya bercak-bercak berwarna jingga di kedua sisi daun. Daun yang terdampak penyakit menunjukkan bintik-bintik coklat yang kemudian menjadi bintik-bintik kuning [6].

Perkembangan bidang teknologi dapat memengaruhi segala aspek kehidupan, salah satunya dalam bidang pertanian. Penggunaan teknologi dalam bidang pertanian, seperti pengolahan citra untuk mendeteksi penyakit pada daun kopi, perlu dilakukan. Pengolahan citra mencakup berbagai bidang, seperti matematika, fisika, elektronika, fotografi, seni, dan teknologi komputer. Oleh karena itu, pengolahan citra berperan penting dalam penelitian ini. Visi komputer dan pemrosesan citra saling terkait. Tugas utama visi komputer meliputi deteksi objek, segmentasi, dan klasifikasi [10].

Proses identifikasi dan klasifikasi penyakit pada daun kopi dilakukan petani secara manual, sehingga kurang efektif karena tidak dapat membedakan karakteristik morfologi, seperti bentuk, tekstur, dan warna pada penyakit daun. Penelitian



Gambar 1. Diagram alir perancangan sistem.

menggunakan pengolahan citra dilakukan untuk mengatasi permasalahan tersebut. Metode *fuzzy k-nearest neighbor* (FK-NN) digunakan pada penelitian sebelumnya untuk mendiagnosis penyakit pada tanaman kopi arabika dengan tingkat akurasi 80% [11]. Penelitian lainnya menerapkan metode *breadth first search* (BFS) berbasis web untuk mendiagnosis hama dan penyakit pada tanaman kopi, dengan akurasi sebesar 83,39% [12]. Penerapan metode *Euclidean distance* dan *Hough transform* terhadap pengenalan penyakit *brown eye spot* pada daun kopi menghasilkan akurasi 55% untuk daun kopi Arabica dan 50% untuk daun kopi Robusta [2]. Pada citra daun tanaman kopi, deteksi tepi menggunakan metode *Laplacian of Gaussian* menghasilkan rata-rata nilai *mean square error* sebesar 237,629 piksel [13]. Penerapan sistem pakar dan layanan berbasis lokasi untuk deteksi penyakit pada tanaman kopi menggunakan klasifikasi *decision tree* juga telah diteliti, dengan tingkat akurasi 85% [14]. Kemudian, studi deteksi penyakit daun kentang menggunakan metode *support vector machine* (SVM) berdasarkan fitur tekstur dan fitur warna memiliki tingkat akurasi rata-rata 80% [15]. Klasifikasi daun cengkeh menggunakan *particle swarm optimization – support vector machine* (PSO-SVM) dan *gray level co-occurrence matrix* (GLCM) untuk menentukan permukaan daun memiliki tingkat akurasi 90,5% [16]. Nilai akurasi 96,8% diperoleh pada penelitian yang menggunakan metode SVM untuk klasifikasi dan *convolutional neural network* (CNN) untuk ekstraksi ciri penyakit pada daun padi [17].

Akurasi klasifikasi yang dicapai menggunakan metode GLCM dan SVM pada penelitian sebelumnya lebih besar dari 80%. Penelitian ini menggunakan metode SVM untuk klasifikasi dan metode GLCM untuk ekstraksi ciri. Proses awal dalam penelitian ini adalah akuisisi data citra untuk mendapatkan citra digital berupa daun kopi robusta. Prapengolahan digunakan untuk meningkatkan kontras citra agar didapatkan nilai RGB baru yang lebih baik. Segmentasi digunakan untuk membedakan daun yang terkena penyakit dan bagian yang tidak terkena penyakit menggunakan *k-means clustering*. Ekstraksi ciri tekstur dilakukan menggunakan proses GLCM, yang menghasilkan nilai *angular second moment* (ASM) atau energi, kontras, korelasi, *inverse different*

moment (IDM) atau homogenitas, dan entropi. Tahap terakhir klasifikasi menggunakan SVM untuk menentukan penyakit daun kopi robusta. Proses ini diolah dengan komputer menggunakan perangkat lunak MATLAB.

II. METODOLOGI

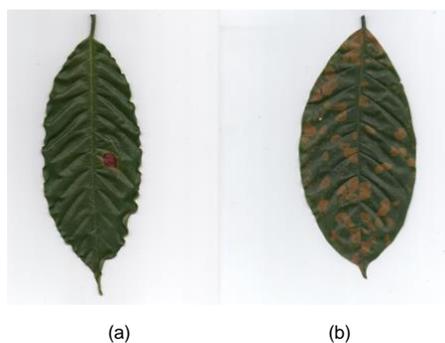
Tahapan metode yang diusulkan ditunjukkan pada Gambar 1, yang meliputi akuisisi citra/mengambil citra, prapengolahan dengan peregangan kontras, segmentasi *k-means clustering*, ekstraksi ciri GLCM, dan klasifikasi SVM. Perancangan sistem, baik pelatihan dan pengujian, memiliki alur proses yang serupa. Diagram alir perancangan sistem berupa pelatihan dan pengujian dapat dituangkan pada Gambar 1, yang menggambarkan alur dalam penelitian yang dilakukan.

A. AKUISISI CITRA

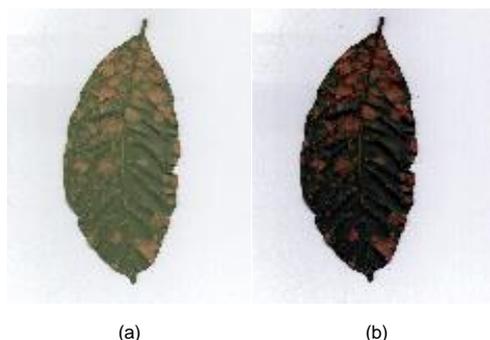
Proses akuisisi citra merupakan tahap awal untuk mengambil atau memperoleh citra digital menggunakan perangkat atau alat tambahan tertentu, dalam penelitian ini menggunakan pemindai digital. Citra daun kopi robusta yang digunakan dalam penelitian ini memiliki ukuran resolusi 300 dpi dalam format JPEG (ekstensi*.jpg). Sampel citra diambil dari perkebunan kopi robusta di daerah Desa Plaosan, Kecamatan Cluwak, Kabupaten Pati, Jawa Tengah. Citra asli yang diambil berupa bercak daun dan karat daun. Data yang diperoleh dibagi menjadi dua bagian, yaitu data latih dan data uji, menggunakan metode *splitting* dengan perbandingan 80:20 [18]. Didapatkan keseluruhan data penelitian ini sebanyak 320 data latih dan 80 data uji. Sampel data berjumlah 200 daun, yang terdiri atas daun kopi dengan penyakit bercak daun dan penyakit karat daun, dengan uraian masing-masing terdiri atas 160 data latih dan 40 data uji. Gambar 2 menunjukkan dua sampel daun kopi.

B. PRAPENGOLAHAN

Prapengolahan digunakan untuk meningkatkan kualitas citra supaya mudah diproses dan dianalisis. Proses meningkatkan kontras untuk memperluas perbedaan citra dilakukan untuk mendapatkan nilai RGB lain dengan diferensiasi yang lebih baik. Perbedaan citra yang signifikan dapat memperluas variasi ketajaman objek pada citra dan citra



Gambar 2. Citra daun kopi robusta, (a) penyakit bercak daun, (b) penyakit karat daun.



Gambar 3. Hasil prapengolahan, (a) citra RGB karat daun, (b) citra karat daun setelah ditingkatkan kontrasnya.

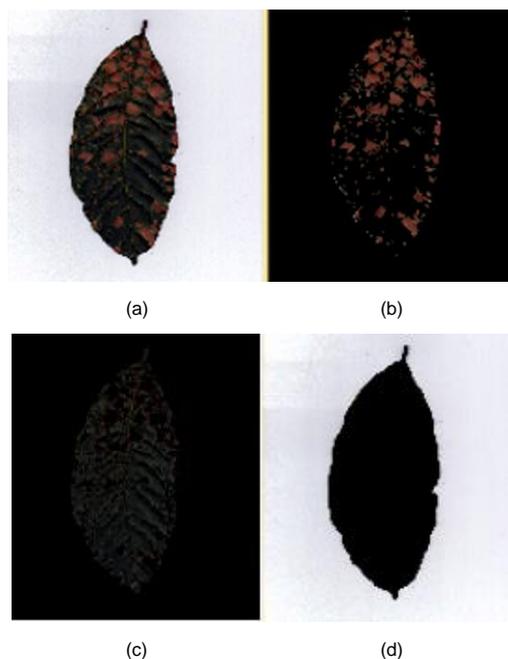
yang terlihat jelas dapat membantu proses segmentasi citra. Selisih antara piksel citra dengan nilai intensitas tertinggi dan nilai intensitas terendah dapat digunakan untuk menentukan kontras. Penelitian ini menggunakan peregang kontras dengan menaikkan nilai intensitas supaya didapatkan citra yang lebih jelas [19], [20]. Proses peningkatan kontras dilakukan menggunakan program MATLAB. Citra asli diekstrak pada masing-masing komponen RGB, kemudian dilakukan peregang kontras untuk mendapatkan kualitas citra yang lebih baik menggunakan fungsi *imadjust*. Gambar 3 menunjukkan hasil peregang kontras citra bercak daun.

C. SEGMENTASI K-MEANS CLUSTERING

Segmentasi digunakan untuk memisahkan suatu daerah menjadi beberapa bagian supaya mudah dianalisis. Citra dibagi menjadi tiga *cluster* menggunakan *k-means clustering*, dengan citra yang terletak di area utama daerah yang terpengaruh setidaknya di salah satu *cluster* [21]. Gambar 4 memperlihatkan segmentasi menggunakan *k-means clustering* untuk memilih dari tiga *cluster* yang lebih terlihat penyakitnya. Gambar 4(a) merupakan citra asli setelah proses prapengolahan, sedangkan Gambar 4(b) sampai Gambar 4(d) adalah hasil *cluster* 1 – 3 dari proses segmentasi *k-means clustering*.

D. EKSTRAKSI CIRI GRAY LEVEL CO-OCCURRENCE MATRIX

Pada proses selanjutnya, bagian hasil segmentasi diekstraksi untuk mendapatkan informasi tentang bagian yang terdampak penyakit. Metode GLCM digunakan untuk ekstraksi ciri. Dalam analisis tekstur, GLCM merupakan metode statistik untuk ekstraksi ciri. Frekuensi piksel dengan nilai intensitas skala abu-abu yang berdekatan secara horizontal dengan piksel senilai *j* dihitung dengan GLCM [22]. Banyaknya tingkatan nilai piksel berdekatan dengan tingkatan nilai piksel lain pada jarak tertentu (*d*) dan arah sudut (θ) dikenal sebagai *co-occurrence*. Piksel mewakili jarak, sedangkan derajat mewakili orientasi. Dengan interval 45° , orientasi terbentuk dalam empat



Gambar 4. Hasil segmentasi *k-means clustering*, (a) citra karat daun, (b) *cluster* 1, (c) *cluster* 2, (d) *cluster* 3.

arah sudut, meliputi $\theta = 0^\circ$, $\theta = 45^\circ$, $\theta = 90^\circ$, dan $\theta = 135^\circ$ [23], [24]. Ciri tekstur dalam penelitian ini dapat dihitung dari GLCM yang dihasilkan, seperti energi, kontras, korelasi, homogenitas, dan entropi. Fitur ekstraksi ciri tekstur adalah sebagai berikut [25]–[27].

1) ANGULAR SECOND MOMENT (ENERGY/UNIFORMITY)

ASM atau energi berguna untuk mengukur intensitas keabuan suatu citra pada matriks GLCM atau keseragaman tekstur. Saat variasi intensitas citra berkurang, nilai ASM meningkat. Persamaan (1) digunakan untuk menghitung nilai ASM.

$$f_1 = \sum_i \sum_j \{p(i, j)\}^2 \quad (1)$$

2) KONTRAS (CONTRAST/INERTIA)

Kontras menggambarkan ukuran penyebaran matriks citra atau momen inersia. Nilai kontras akan makin tinggi jika jauh dari diagonal utama. Nilai kontras adalah indikator visual tentang perbedaan tingkat keabuan di area citra satu dengan lainnya. Persamaan (2) digunakan untuk menentukan nilai kontras, yaitu sebagai berikut.

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\} \quad (2)$$

3) KORELASI (CORRELATION)

Ukuran ketergantungan linear antara nilai derajat keabuan citra ditunjukkan oleh korelasi. Persamaan (3) digunakan untuk menentukan nilai korelasi.

$$f_3 = \frac{\sum_i \sum_j (i-j)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

4) INVERSE DIFFERENCE MOMENT (HOMOGENEITY)

Ciri yang menunjukkan homogenitas citra pada matriks *co-occurrence* dengan derajat keabuan yang sama adalah momen selisih terbalik. Pada beberapa koordinat, jika pasangan piksel memenuhi persyaratan dari kemungkinan matriks kejadian bersama, nilai energi akan naik, sedangkan jika letaknya menyebar, nilai energi akan turun. Hasilnya adalah citra yang homogen dapat dikatakan memiliki nilai IDM yang tinggi.

Persamaan yang digunakan untuk menentukan nilai IDM ditunjukkan dalam (4).

$$f_4 = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j). \quad (4)$$

5) ENTROPI (ENTROPY)

Ketidakteraturan distribusi intensitas tingkat keabuan citra dalam matriks *co-occurrence* dapat diukur dengan menggunakan entropi. Tampilan akan lebih tinggi jika nilai relatif elemen GLCM sama. Tampilan akan buruk jika nilai elemen GLCM mendekati 0 atau 1. Ini berarti transisi abu-abu kecil, sedangkan perubahannya juga kecil. Nilai entropi dihitung menggunakan (5).

$$f_5 = - \sum_i \sum_j p(i, j) \log(p(i, j)). \quad (5)$$

Pada (1) sampai (5), $p(i, j)$ merupakan (i, j) masukan dalam matriks ketergantungan spasial aras keabuan yang dinormalisasi, $\frac{P(i, j)}{R}$. Dalam nilai $P_x(i)$, (i) dimasukkan ke dalam matriks probabilitas rendah yang diperoleh dengan menjumlahkan baris-baris dari $P(i, j) = \sum_{j=1}^{N_g} P(i, j)$. Nilai n merupakan jumlah tingkat keabuan dalam citra, sedangkan N_g merupakan jumlah tingkat keabuan yang berbeda dalam masing-masing citra terkuantisasi $\sum_i, \sum_j, \sum_{i=1}^{N_g}$, dan $\sum_{j=1}^{N_g}$. Nilai $\mu_x \mu_y$ merupakan rata-rata elemen kolom pada matriks citra, sedangkan nilai $\sigma_x \sigma_y$ merupakan standar deviasi elemen kolom matriks.

Ciri tekstur dalam penelitian ini dapat dihitung dari GLCM yang dihasilkan, seperti ASM/energi, kontras, korelasi, IDM/homogenitas, dan entropi. Empat arah pembentukan ciri tekstur adalah 0° , 45° , 90° , dan 135° , masing-masing dengan interval 45° . Nilai GLCM akan ditentukan dengan menghitung jarak antar piksel (d) = 1, 2, dan 3.

E. KLASIFIKASI SUPPORT VECTOR MACHINE

Klasifikasi setelah ekstraksi ciri tekstur dilakukan menggunakan metode SVM. SVM adalah pembelajaran terawasi menggunakan algoritma yang dapat menganalisis data dan mengidentifikasi pola untuk memberikan dukungan berkualitas tinggi untuk *hyperplane* dalam ruang dimensi [28]. SVM digunakan dalam analisis regresi dan klasifikasi untuk mengidentifikasi penyakit pada tanaman kopi. Untuk masalah nonlinear, ide *kernel trick* di ruang kerja berdimensi tinggi disertakan dalam pengembangan SVM di masa mendatang. Ide dasar SVM adalah klasifikasi linear. Beberapa fungsi *kernel* dapat digunakan dalam kasus nonlinear. Proses pembelajaran SVM menjadi lebih mudah dengan *kernel trick*. Klasifikasi SVM memiliki beberapa fungsi *kernel* yang sering digunakan, di antaranya sebagai berikut [29]–[31].

1) KERNEL LINEAR

Dari semua fungsi *kernel*, *kernel* linear adalah yang paling sederhana. Dalam kasus klasifikasi teks, *kernel* ini sering digunakan. Untuk menentukan *kernel* linear, digunakan (6).

$$K(x_i, x_j) = x_i \cdot x_j. \quad (6)$$

2) KERNEL POLINOMIAL

Kernel yang sering digunakan untuk mengklasifikasikan citra adalah *kernel* polinomial. Persamaan (7) digunakan untuk menentukan *kernel* polinomial.

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d. \quad (7)$$

3) KERNEL RADIAL BASIS FUNCTION (RBF) GAUSSIAN

Kernel RBF, yang merupakan *kernel* standar untuk data yang valid (tersedia), adalah salah satu *tool* yang digunakan sebagai *tool* SVM secara *default*. Persamaan (8) menentukan *kernel* RBF.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right). \quad (8)$$

Pada (6) sampai (8), $K(x_i, x_j)$ merupakan fungsi *kernel*, sedangkan nilai x_i, x_j merupakan sepasang dua data dari seluruh kumpulan data pelatihan. Nilai c, d, σ merupakan konstanta dan $\|x_i - x_j\|^2$ merupakan kuadrat jarak antara vektor x_i dan x_j .

Penelitian ini memanfaatkan *kernel* pada metode SVM untuk sistem klasifikasinya. *Kernel* yang digunakan adalah *kernel* linear, polinomial, dan RBF Gaussian. Penyakit bercak daun atau karat daun kopi merupakan hasil klasifikasi.

F. EVALUASI TINGKAT KEBERHASILAN KLASIFIKASI

Cara mengetahui tingkat keberhasilan klasifikasi dari algoritma pembelajaran mesin adalah menggunakan *confusion matrix* yang berisikan informasi aktual dan prediksi hasil klasifikasi. Akurasi menyatakan jumlah kasus yang diklasifikasikan benar dibagi dengan jumlah keseluruhan data. Akurasi dihitung menggunakan (9). Makin tinggi akurasi klasifikasi, makin baik kinerja teknik klasifikasi. Presisi dan *recall* digunakan sebagai ukuran ketepatan dan kelengkapan hasil klasifikasi, yang dihitung menggunakan (10) dan (11). *F1-score* merupakan rata-rata harmonik presisi dan *recall*, dihitung menggunakan (12) [32], [33].

$$\text{Akurasi} = \frac{TN+TP}{TN+TP+FN+FP} \quad (9)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (10)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (11)$$

$$F1 - \text{score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (12)$$

Hasil evaluasi bergantung dari nilai *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN).

III. HASIL DAN PEMBAHASAN

Pengujian sistem dilakukan dengan menguji citra yang sudah diperoleh sebelumnya. Citra diperoleh menggunakan pemindai digital supaya didapatkan jarak yang sama antara citra yang satu dengan lainnya. Pengujian dilakukan sebanyak 27 kali dengan tiga *kernel* klasifikasi SVM. Tabel I menunjukkan tiga *cluster* segmentasi *k-means clustering* dan tiga jarak antara piksel ekstraksi ciri GLCM. Skenario 1 sampai 9 pengujian klasifikasi SVM menggunakan *kernel* linear dengan tiga *cluster* segmentasi *k-means clustering* dan tiga jarak antarpiksel ekstraksi ciri GLCM. Skenario 10 sampai 18 pengujian klasifikasi SVM menggunakan *kernel* polinomial dengan tiga *cluster* segmentasi *k-means clustering* dan tiga jarak antarpiksel ekstraksi ciri GLCM. Skenario 19 sampai 27 pengujian klasifikasi SVM menggunakan *kernel* RBF Gaussian dengan tiga *cluster* segmentasi *k-means clustering* dan tiga jarak antarpiksel ekstraksi ciri GLCM.

A. PEMBAHASAN DAN EVALUASI HASIL PENGUJIAN SVM KERNEL LINEAR

Terdapat sejumlah faktor yang memengaruhi akurasi, presisi, *recall*, dan *F1-score* dari pengujian klasifikasi SVM

TABEL I
SKENARIO PENELITIAN

Skenario	<i>K-Means Clustering</i>	GLCM
	<i>Cluster</i>	<i>Jarak (piksel)</i>
1, 10, 19	1	1
2, 11, 20	1	2
3, 12, 21	1	3
4, 13, 22	2	1
5, 14, 23	2	2
6, 15, 24	2	3
7, 16, 25	3	1
8, 17, 26	3	2
9, 18, 27	3	3

TABEL II
HASIL EVALUASI PENGUJIAN SVM LINEAR

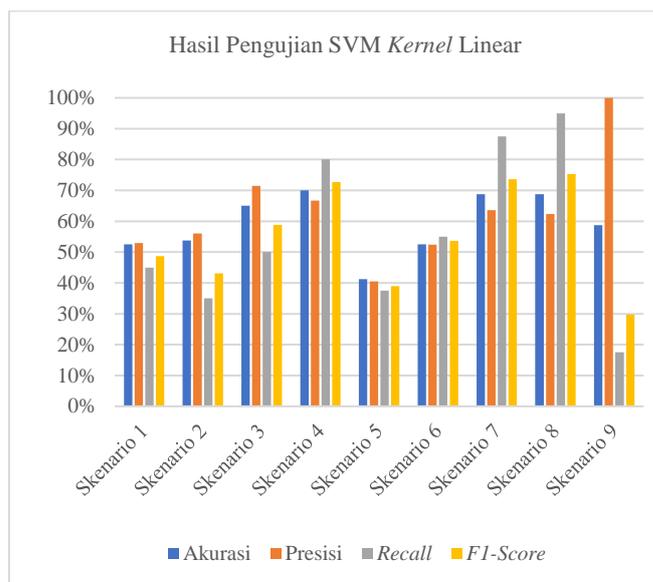
Skenario	Hasil Pengujian SVM Linear			
	<i>Akurasi</i>	<i>Presisi</i>	<i>Recall</i>	<i>F1-Score</i>
1	52,50%	52,94%	45,00%	48,65%
2	53,75%	56,00%	35,00%	43,08%
3	65,00%	71,43%	50,00%	58,82%
4	70,00%	66,67%	80,00%	72,73%
5	41,25%	40,54%	37,50%	38,96%
6	52,50%	52,38%	55,00%	53,66%
7	68,75%	63,64%	87,50%	73,68%
8	68,75%	62,30%	95,00%	75,25%
9	58,75%	100,00%	17,50%	29,79%

dengan *kernel* linear. Beberapa faktor yang memengaruhi di antaranya *cluster* pada proses segmentasi *k-means clustering* dan jarak antarpiksel pada ekstraksi ciri GLCM. Pada penelitian ini digunakan tiga *cluster* dan tiga jarak antarpiksel. Hasil pengujian didapatkan dari nilai ekstraksi ciri GLCM yang dihasilkan, seperti energi, kontras, korelasi, homogenitas, dan entropi dengan sudut 0°, 45°, 90°, 135°, dan rata-rata sudut. Tabel II menunjukkan hasil pengujian dari evaluasi menggunakan dua jenis daun, yaitu penyakit bercak daun dan karat daun dengan *kernel* linear.

Pada skenario 1 sampai skenario 9, pengujian klasifikasi SVM menggunakan *kernel* linear ditunjukkan pada Tabel II dan Gambar 5. Akurasi tertinggi diperoleh pada skenario 4, yaitu sebesar 70%, presisi tertinggi pada skenario 9 sebesar 100%, *recall* tertinggi pada skenario 8 sebesar 95%, dan *F1-score* tertinggi pada skenario 8 sebesar 75,25%. Diagram pengujian pada Gambar 5 menunjukkan nilai akurasi naik saat jarak antarpiksel makin tinggi, yang terjadi pada *cluster* 1. Akan tetapi, pada *cluster* 2 dan 3 nilai akurasi tidak stabil saat jarak antarpiksel dinaikkan. Tidak stabilnya nilai akurasi disebabkan oleh acaknya hasil segmentasi, sehingga tiga *cluster* citra dengan area terdeteksi dan tidak terdeteksi penyakit akan tampil secara acak. Nilai presisi dan *recall* bergantung pada hasil klasifikasi pertama, yaitu bercak daun. Makin banyak klasifikasi yang benar, makin baik nilainya. Hasil presisi dan *recall* menentukan nilai *F1-score*. Makin baik nilai presisi dan *recall*, makin baik pula nilai *F1-score*.

B. PEMBAHASAN DAN EVALUASI HASIL PENGUJIAN SVM KERNEL POLINOMIAL

Terdapat sejumlah faktor yang memengaruhi akurasi, presisi, *recall*, dan *F1-score* dari pengujian klasifikasi SVM dengan *kernel* polinomial. Beberapa faktor yang memengaruhi



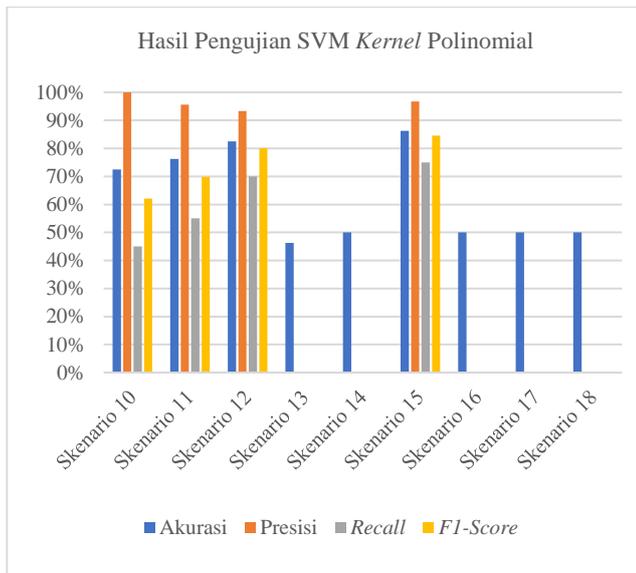
Gambar 5. Grafik hasil evaluasi pengujian SVM *kernel* linear.

TABEL III
HASIL EVALUASI PENGUJIAN SVM POLINOMIAL

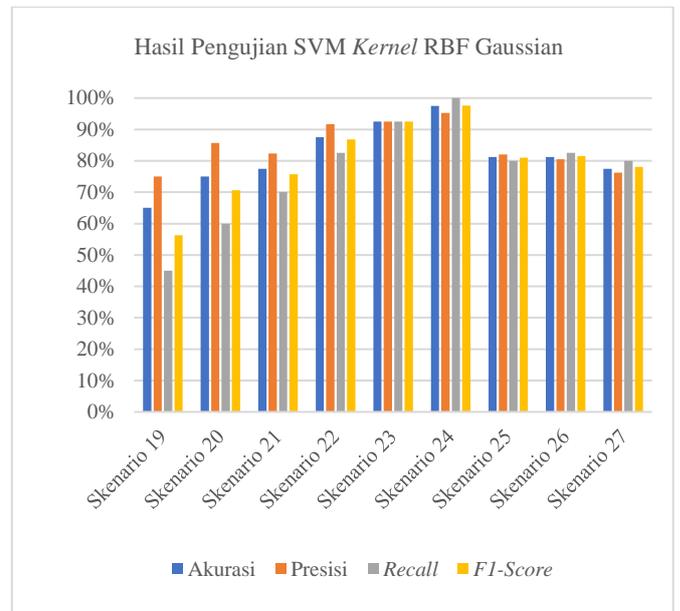
Skenario	Hasil Pengujian SVM Polinomial			
	<i>Akurasi</i>	<i>Presisi</i>	<i>Recall</i>	<i>F1-Score</i>
10	72,50%	100,00%	45,00%	62,07%
11	76,25%	95,65%	55,00%	69,84%
12	82,50%	93,33%	70,00%	80,00%
13	46,25%	0,00%	0,00%	0,00%
14	50,00%	0,00%	0,00%	0,00%
15	86,25%	96,77%	75,00%	84,51%
16	50,00%	0,00%	0,00%	0,00%
17	50,00%	0,00%	0,00%	0,00%
18	50,00%	0,00%	0,00%	0,00%

tersebut di antaranya adalah *cluster* pada proses segmentasi *k-means clustering* dan jarak antarpiksel pada ekstraksi ciri GLCM. Penelitian ini menggunakan tiga *cluster* dan tiga jarak antarpiksel. Hasil pengujian diperoleh dari nilai ekstraksi ciri GLCM yang dihasilkan, seperti energi, kontras, korelasi, homogenitas, dan entropi dengan sudut 0°, 45°, 90°, 135°, dan rata-rata sudut. Tabel III menunjukkan hasil pengujian dari evaluasi menggunakan dua jenis daun, yaitu penyakit bercak daun dan karat daun dengan *kernel* polinomial.

Pengujian klasifikasi SVM dengan skenario 10 sampai 18 menggunakan *kernel* polinomial, seperti ditunjukkan pada Tabel III dan Gambar 6. Hasil tertinggi akurasi didapatkan pada skenario 15, yaitu sebesar 86,25%, presisi tertinggi pada skenario 10 sebesar 100%, *recall* tertinggi pada skenario 15 sebesar 75%, dan *F1-score* tertinggi pada skenario 15 sebesar 84,51%. Diagram pengujian pada Gambar 6 menunjukkan bahwa akurasi naik saat jarak antarpiksel makin tinggi, yang terjadi pada *cluster* 1 dan 2. Akan tetapi, pada *cluster* 3 nilai akurasi stabil saat nilai jarak antarpiksel dinaikkan. Tidak stabilnya nilai akurasi disebabkan oleh acaknya hasil segmentasi, sehingga tiga *cluster* citra dengan area terdeteksi dan tidak terdeteksi penyakit akan tampil secara acak. Nilai presisi dan *recall* bergantung pada hasil klasifikasi pertama, yaitu bercak daun. Pada *cluster* 3 nilainya nol karena hasil klasifikasi pada karat daun salah semua. Hasil dari presisi dan



Gambar 6. Grafik hasil evaluasi pengujian SVM kernel polinomial.



Gambar 7. Grafik hasil evaluasi pengujian SVM kernel RBF Gaussian.

TABEL IV
HASIL EVALUASI PENGUJIAN SVM RBF GAUSSIAN

Skenario	Hasil Pengujian SVM RBF Gaussian			
	Akurasi	Presisi	Recall	F1-Score
19	65,00%	75,00%	45,00%	56,25%
20	75,00%	85,71%	60,00%	70,59%
21	77,50%	82,35%	70,00%	75,68%
22	87,50%	91,67%	82,50%	86,84%
23	92,50%	92,50%	92,50%	92,50%
24	97,50%	95,24%	100,00%	97,56%
25	81,25%	82,05%	80,00%	81,01%
26	81,25%	80,49%	82,50%	81,48%
27	77,50%	76,19%	80,00%	78,05%

TABEL V
HASIL KINERJA SVM TERBAIK

No.	Kernel	Akurasi	Presisi	Recall	F1-Score
1	Linear	70,00%	66,67%	80,00%	72,73%
2	Polinomial	86,25%	96,77%	75,00%	84,51%
3	RBF Gaussian	97,50%	95,24%	100,00%	97,56%

recall berpengaruh terhadap nilai F1-score. Makin baik nilai presisi dan recall, makin baik pula nilai F1-score, dan sebaliknya.

C. PEMBAHASAN DAN EVALUASI HASIL PENGUJIAN SVM KERNEL RBF GAUSSIAN

Hasil pengujian klasifikasi SVM menggunakan kernel RBF Gaussian, berupa tingkat akurasi, presisi, recall, dan F1-score, dipengaruhi oleh beberapa faktor, di antaranya cluster pada proses segmentasi k-means clustering dan jarak antarpiksel pada ekstraksi ciri GLCM. Penelitian ini dilakukan menggunakan tiga clust dan tiga jarak antarpiksel. Hasil pengujian diperoleh dari nilai ekstraksi ciri GLCM yang dihasilkan, seperti energi, kontras, korelasi, homogenitas, dan entropi dengan sudut 0°, 45°, 90°, 135°, dan rata-rata sudut. Tabel IV menunjukkan hasil pengujian dari evaluasi menggunakan dua jenis daun, yaitu penyakit bercak daun dan karat daun dengan kernel RBF Gaussian.

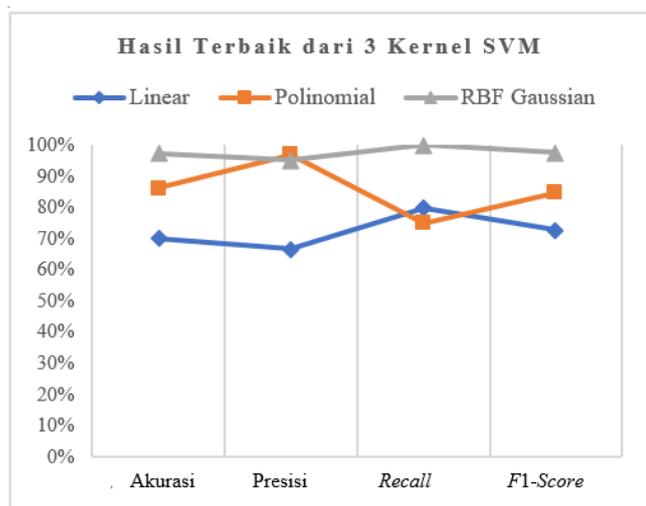
Pengujian klasifikasi SVM menggunakan kernel RBF Gaussian dengan skenario 19 sampai skenario 27 ditunjukkan pada Tabel IV dan Gambar 7. Hasil tertinggi akurasi didapatkan pada skenario 24 sebesar 97,5%, presisi tertinggi pada skenario 24 sebesar 95,24%, recall tertinggi pada skenario 24 sebesar 100%, dan F1-score tertinggi pada skenario 24 sebesar 97,56%. Diagram pengujian pada Gambar 7 menunjukkan bahwa nilai akurasi naik saat jarak antarpiksel makin tinggi, yang terjadi pada cluster 1 dan 2. Akan tetapi,

pada cluster 3 nilai akurasi menurun saat nilai jarak antarpiksel dinaikkan. Tidak stabilnya nilai akurasi disebabkan oleh acaknya hasil segmentasi, sehingga tiga cluster citra dengan area terdeteksi dan tidak terdeteksi penyakit akan tampil secara acak. Nilai presisi dan recall bergantung pada hasil klasifikasi pertama, yaitu bercak daun. Makin banyak klasifikasi yang benar, makin baik nilai presisi dan recall. Hasil dari presisi dan recall berpengaruh terhadap nilai F1-score. Makin baik nilai presisi dan recall, makin baik pula nilai F1-score, begitu pula sebaliknya.

D. HASIL KINERJA KERNEL SVM

Hasil kinerja klasifikasi jenis penyakit daun kopi robusta berupa bercak daun dan karat daun dengan segmentasi k-means clustering dibagi menjadi tiga cluster, yaitu dapat mendeteksi bagian yang terdapat penyakit bercak daun dan karat daun. energi, kontras, korelasi, homogenitas, dan entropi adalah parameter GLCM yang digunakan dalam penelitian ini. Keempat sudut 0°, 45°, 90°, dan 135°, dengan jarak antarpiksel 1, 2, dan 3, digunakan untuk membentuk parameter-parameter tersebut. Metode SVM digunakan untuk sistem klasifikasi dengan kernel linear, polinomial, dan RBF Gaussian. Tabel V menunjukkan hasil pengujian dengan kinerja terbaik dari tiga kernel.

Gambar 8 menunjukkan hasil pengujian nilai akurasi dengan kombinasi cluster dari k-means clustering, parameter GLCM, dan kernel SVM yang diajukan. Kernel RBF Gaussian memberikan kinerja yang terbaik di antara kernel yang lainnya. Pengujian nilai presisi terbaik berdasarkan akurasi diperoleh pada kernel polinomial, sedangkan recall dan F1-score terbaik pada kernel RBF Gaussian. Kernel pada klasifikasi SVM juga



Gambar 8. Grafik hasil evaluasi terbaik pengujian SVM.

berpengaruh terhadap tingkat akurasi yang didapatkan saat penelitian.

IV. KESIMPULAN

Pada penelitian ini telah dilakukan klasifikasi SVM pada penyakit daun kopi robusta berdasarkan ekstraksi ciri GLCM. Proses segmentasi dilakukan menggunakan *k-means clustering* dengan tiga *cluster*. Ekstraksi ciri GLCM menggunakan fitur energi, kontras, korelasi, homogenitas, dan entropi dengan sudut 0°, 45°, 90°, 135°, dan rata-rata sudut, serta 1 sampai 3 jarak antarpiksel. Klasifikasi metode SVM menggunakan *kernel* linear, polinomial, dan RBF Gaussian. Hasil pengujian terbaik klasifikasi penyakit bercak daun dan karat daun kopi robusta diperoleh dengan *kernel* RBF Gaussian. Hasil akurasi tertinggi sebesar 97,5%, presisi sebesar 95,24%, *recall* sebesar 100%, dan *F1-score* sebesar 97,56%. Penggunaan *kernel* pada metode SVM sangat berpengaruh dalam proses klasifikasi. Dari tiga *kernel* yang digunakan saat penelitian, yaitu linear, polinomial, dan RBF Gaussian, didapatkan nilai akurasi tertinggi pada pengujian menggunakan *kernel* RBF Gaussian.

Namun, penelitian ini masih memiliki kekurangan, salah satunya pada prapengolahan citra. Perlu dilakukan penelitian lanjutan untuk mendapatkan model prapengolahan dan mengenali ciri spesifik dari bercak daun dan karat daun yang lebih tepat, sehingga hasil klasifikasi memiliki akurasi tinggi. Perlu dilakukan pengujian penyakit daun kopi robusta dengan metode yang lainnya, misalnya *deep learning*. Kemudian, penelitian tersebut dibandingkan dengan penelitian ini untuk mendapatkan metode terbaik.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan.

KONTRIBUSI PENULIS

Konseptualisasi, Agus Supriyanto; metodologi, Agus Supriyanto; perangkat lunak, Agus Supriyanto; validasi, Agus Supriyanto; formal analysis, R Rizal Isnanto and Oky Dwi Nurhayati; sumber daya, Agus Supriyanto; data curation, R Rizal Isnanto and Oky Dwi Nurhayati; penulisan, Agus Supriyanto; akuisisi pendanaan, R Rizal Isnanto and Oky Dwi Nurhayati.

REFERENSI

[1] M. Rizwan, *Budidaya Kopi*. Pasaman Barat, Indonesia: CV. Azka Pustaka, 2022.

[2] Y. Defitri, "Pengamatan Beberapa Penyakit yang Menyerang Tanaman Kopi (*Coffea Sp*) di Desa Mekar Jaya Kecamatan Betara Kabupaten Tanjung Jabung Barat," *J. Media Pertan.*, Vol. 1, No. 2, hal. 78–84, Okt. 2016, doi: 10.33087/jagro.v1i2.19.

[3] I. Fibriani, Widjonarko, C.S. Sarwono, dan F. Dwika, "Deteksi Penyakit Brown Eye Spot pada Daun Kopi Menggunakan Metode Euclidean Distance dan Hough Transform," *J. JEETech*, Vol. 1, No. 1, hal. 44–49, Mei 2020, doi: 10.48056/jeetech.v1i2.120.

[4] A.S. Franca dan L.S. Oliveira, "Coffee," dalam *Integrated Processing Technologies for Food and Agricultural By-Products*, Z. Pan, R. Zhang, dan S. Zicari, Eds., Cambridge, AS: Academic Press, 2019, hal. 413–438, doi: 10.1016/B978-0-12-814138-0.00017-4

[5] International Coffee Organization, "Total Production by All Exporting Countries." Didistribusikan oleh International Coffee Organization, <https://www.ico.org/historical/1990%20onwards/PDF/1a-total-production.pdf>

[6] R. Harni dkk., *Teknologi Pengendalian Hama dan Penyakit Tanaman Kopi*, ed. 2. Jakarta, Indonesia: IAARD Press, 2018.

[7] U.D. Rosiani, C. Rahmad, M.A. Rahmawati, dan F. Tupamahu, "Segmentasi Berbasis K-Means pada Deteksi Citra Penyakit Daun Tanaman Jagung," *J. Inform. Polinema*, Vol. 6, No. 3, hal. 37–42, Mei 2020, doi: 10.33795/jip.v6i3.331.

[8] E.P. Ramdan dkk., *Penyakit Tanaman dan Pengendaliannya*. Medan, Sumatera Utara: Yayasan Kita Menulis, 2021.

[9] N.E.T. Castillo dkk., "Impact of Climate Change and Early Development of Coffee Rust – An Overview of Control Strategies to Preserve Organic Cultivars in Mexico," *Sci. Total Environ.*, Vol. 738, hal. 1–14, Okt. 2020, doi: 10.1016/j.scitotenv.2020.140225.

[10] W. Li dkk., "Intelligent Metasurface System for Automatic Tracking of Moving Targets and Wireless Communications Based on Computer Vision," *Nat. Commun.*, Vol. 14, hal. 1–10, Feb. 2023, doi: 10.1038/s41467-023-36645-3.

[11] A.Y.P. Putri, "Pemodelan Sistem Pakar Diagnosa Penyakit Tanaman Kopi Arabika Dengan Metode Fuzzy K-Nearest Neighbor (FK-NN)," Skripsi, Universitas Brawijaya, Malang, Indonesia, 2015.

[12] F.R. Lumbanraja, S. Rosdiana, H. Sudarsono, dan A. Junaidi, "Sistem Pakar Diagnosis Hama dan Penyakit Tanaman Kopi Menggunakan Metode Breadth First Search (Bfs) Berbasis Web," *Explore J. Sist. Inf. Telemat.*, Vol. 11, No. 1, hal. 1–9, Jun. 2020, doi: 10.36448/jsit.v11i1.1452.

[13] T.S. Prihartini dan P.N. Andono, "Deteksi Tepi dengan Metode Laplacian of Gaussian pada Citra Daun Tanaman Kopi," Skripsi, Universitas Dian Nuswantoro, Semarang, Indonesia, 2015.

[14] W.A. Nugraha, M. Lestari, M. Yasin, dan D. Suhartono, "Perancangan Sistem Pakar Pendeteksi Penyakit pada Tanaman Kopi dengan Layanan Berbasis Lokasi," tanggal akses: 20-Jun-2023, [Online], <https://socs.binus.ac.id/2014/07/18/perancangan-sistem-pakar-pendeteksi-penyakit-pada-tanaman-kopi-dengan-layanan-berbasis-lokasi/>

[15] P.U. Rakhmawati, Y.M. Pranoto, dan E. Setyati, "Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Fitur Warna Menggunakan Support Vector Machine," *Seminar Nas. Teknol., Rekrayasa (SENTRA) 2018*, 2018, hal. 1–8, doi: 10.22219/sentra.v0i4.2127.

[16] S.I. Novichasari dan Y.S. Sipayung, "PSO-SVM untuk Klasifikasi Daun Cengkeh Berdasarkan Morfologi Bentuk Ciri, Warna dan Tekstur GLCM Permukaan Daun," *J. Multimatrix*, Vol. 1, No. 1, hal. 18–21, Des. 2018.

[17] F. Jiang dkk., "Image Recognition of Four Rice Leaf Diseases Based on Deep Learning and Support Vector Machine," *Comput., Electron. Agriculture*, Vol. 179, hal. 1–9, Des. 2020, doi: 10.1016/j.compag.2020.105824.

[18] Trivusi (2022) "Data Splitting: Pengertian, Metode, dan Kegunaannya," [Online], <https://www.trivusi.web.id/2022/08/data-splitting.html>, tanggal akses: 20-Jun-2023.

[19] L. Hussain dkk., "Lung Cancer Prediction Using Robust Machine Learning and Image Enhancement Methods on Extracted Gray-Level Co-occurrence Matrix Features," *Appl. Sci.*, Vol. 12, No. 13, hal. 1–20, Jun. 2022, doi: 10.3390/app12136517.

[20] I.M.O Widyantara, N.M.A.E.D Wirastuti, dan I.B.P. Adnyana, "Metode Contrast Stretching untuk Perbaikan Kualitas Citra pada Proses Segmentasi Video," *Maj. Ilm. Teknol. Elekt.*, Vol. 16, No. 2, hal. 1–6, Mei–Agu. 2017, doi: 10.24843/MITE.2017.v16i02p01.

[21] H. Armagan, "K-Means Kumeleme Algoritması ile Renk Tabanlı Segmantasyon ve Renk Uzaylarının Görüntü Niceliklerine Etkisinin Sayısal Analizi," *El-Cezerê J. Sci., Eng.*, Vol. 9, No. 4, hal. 1506–1517,

- Des. 2022, doi: 10.31202/ecjse.1141148.
- [22] N. Mourya, Vidyashanakara, dan G.H. Kumar, "Leaf Classification Based on GLCM Texture and SVM," *Int. J. Comput. Appl.*, Vol. 4, No. 3, hal. 156–159, Mar. 2018, doi: 10.5120/ijca2020919846.
- [23] E. Alvansga, "Pengenalan Tekstur Menggunakan Metode GLCM serta Modul Nirkabel," Skripsi, Universitas Sanata Dharma, Yogyakarta, Indonesia, 2019.
- [24] M. Furqan, S. Sriani, dan L.S. Harahap, "Klasifikasi Daun Bugenvil Menggunakan Gray Level Co-Occurrence Matrix dan K-Nearest Neighbor," *J. CoreIT*, Vol. 6, No. 1, hal. 22–29, Jun. 2020, doi: 10.24014/coreit.v6i1.9296.
- [25] R. Suganya, S. Rajaram, dan A.S. Abdullah, *Big Data in Medical Image Processing*, ed. 1. Florida, AS: CRC Press, 2018, doi: 10.1201/b22456.
- [26] M.F.T. Putra, "Penerapan Gray Level Co-Occurrence Matrix (GLCM) dan Learning Vector Quantization (LVQ) untuk Klasifikasi Penyakit Retina Mata," Tugas Akhir, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia, 2021.
- [27] J. Webel, J. Gola, D. Britz, dan F. Mücklich, "A New Analysis Approach Based on Haralick Texture Features for the Characterization of Microstructure on the Example of Low-Alloy Steels," *Mater. Charact.*, Vol. 144, hal. 584–596, Okt. 2018, doi: 10.1016/j.matchar.2018.08.009.
- [28] Y.M. Oo dan N.C. Htun, "Plant Leaf Disease Detection and Classification Using Image Processing," *Int. J. Res., Eng.*, Vol. 5, No. 9, hal. 516–523, Sep.–Okt. 2018, doi: 10.21276/ijre.2018.5.9.4.
- [29] E. Prasetyo, *Data Mining: Mengolah Data Menjadi Informasi Menggunakan Matlab*, ed. 1. Yogyakarta, Indonesia: Andi, 2014.
- [30] F. Hilmiyah, "Prediksi Kinerja Mahasiswa Menggunakan Support Vector Machine untuk Pengelola Program Studi di Perguruan Tinggi (Studi Kasus: Program Studi Magister Statistika ITS)," Tesis, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 2017.
- [31] Y.F. Khan, B. Kaushik, C.L. Chowdhary, dan G. Srivastava, "Ensemble Model for Diagnostic Classification of Alzheimer's Disease Based on Brain Anatomical Magnetic Resonance Imaging," *Diagnostics*, Vol. 12, No. 12, hal. 1–27, Des. 2022, doi: 10.3390/diagnostics12123193.
- [32] S. Adinugroho dan Y.A. Sari, *Implementasi Data Mining Menggunakan Weka*, ed. 1. Malang, Indonesia: UB Press, 2018.
- [33] A.N. Rais, W. Warjiono, W. Kurniawan, dan R. Ardianto "Analisa Akurasi dan F1 Score pada Algoritma Smote dan Naïve Bayes pada Dataset Bank Direct Marketing," *Speed-Sentra Penelit. Eng., Edukasi*, Vol. 11, No. 4, hal. 1–7, Okt. 2019, doi: 10.55181/speed.v11i4.620.