

**KLASIFIKASI TANAMAN HERBAL BERDASARKAN CITRA DAUN
MENGUNAKAN METODE MULTICLASS SUPPORT VECTOR MACHINE**

SKRIPSI

Oleh:

VINKA ROSALIA FATIMAH DEVI
NIM. 210605110087



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**KLASIFIKASI TANAMAN HERBAL BERDASARKAN CITRA DAUN
MENGUNAKAN METODE MULTICLASS SUPPORT VECTOR
MACHINE**

SKRIPSI

Diajukan Kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
VINKA ROSALIA FATIMAH DEVI
NIM. 210605110087

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

KLASIFIKASI TANAMAN HERBAL BERDASARKAN CITRA DAUN MENGUNAKAN METODE MULTICLASS SUPPORT VECTOR MACHINE

SKRIPSI

Oleh :
VINKA ROSALIA FATIMAH DEVI
NIM. 210605110087

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 29 Juni 2026

Pembimbing I,



Dr. Totok Chamidy, M. Kom
NIP. 19691222 200604 1 001


Pembimbing II,



Nurizal Dwi Priandani, M. Kom
NIP. 199208302022031001

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Supriyono, M. Kom

NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

KLASIFIKASI TANAMAN HERBAL BERDASARKAN CITRA DAUN MENGUNAKAN METODE MULTICLASS SUPPORT VECTOR MACHINE

SKRIPSI

Oleh :
VINKA ROSALIA FATIMAH DEVI
NIM. 210605110087

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 29 Juni 2026

Susunan Dewan Penguji

Ketua Penguji : Dr. M. Ainul Yaqin, M.Kom
NIP. 19761013 200604 1 004


Anggota Penguji I : Tri Mukti Lestari, M.Kom
NIP. 199111082020122005


Anggota Penguji II : Dr. Totok Chamidy, M. Kom
NIP. 19691222 200604 1 001

Anggota Penguji III : Nurizal Dwi Priandani, M.Kom
NIP. 199208302022031001

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Saptiyono, M. Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Vinka Rosalia Fatimah devi

NIM : 210605110087

Fakultas / Jurusan : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Klasifikasi Tanaman Herbal Berdasarkan Citra Daun
Menggunakan Metode Multiclass Support Vector Machine

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 29 Juni 2026
Yang membuat pernyataan,



Vinka Rosalia Fatimah Devi
NIM.210605110087

MOTTO

Tenang dalam proses, sabar dalam langkah, dan yakin bahwa setiap hasil dari usaha akan menemukan waktunya

HALAMAN PERSEMBAHAN

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, nikmat, serta karunia-Nya yang tiada henti diberikan. Berkat izin, pertolongan, dan kemudahan dari-Nya, penulis dapat menyelesaikan skripsi ini.

Dengan penuh rasa syukur dan ketulusan hati, karya sederhana ini penulis persembahkan kepada keluarga tersayang yang senantiasa memberikan kasih sayang, doa, dukungan, serta pengorbanan yang tidak ternilai harganya. Terima kasih atas setiap nasihat, kesabaran, dan kepercayaan yang selalu diberikan kepada penulis.

Dan untuk diri saya sendiri, terima kasih telah berjuang dan bertahan hingga sampai pada titik ini. Semoga setiap usaha yang telah dilakukan membawa manfaat dan keberkahan di masa yang akan datang.

KATA PENGANTAR

Assalamu 'alaikum warahmatullahi wabarakatuh

Puji syukur penulis panjatkan ke hadirat Allah Subhanahu wa Ta'ala, karena berkat rahmat, karunia, dan pertolongan-Nya, penulis akhirnya mampu menyelesaikan skripsi ini hingga tuntas. Shalawat serta salam tak lupa penulis haturkan kepada junjungan kita, Nabi Muhammad SAW, dengan harapan kelak kita semua termasuk golongan yang mendapatkan syafa'atnya di hari akhir. Aamiin.

Tersusunnya skripsi ini tidak terlepas dari bantuan, bimbingan, serta dorongan dari berbagai pihak. Oleh sebab itu, penulis ingin menyampaikan rasa terima kasih yang setulus-tulusnya kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes., selaku Dekan Fakultas Sains dan Teknologi.
3. Supriyono, M.Kom., selaku Ketua Program Studi Teknik Informatika.
4. Dr. Totok Chamidy, M.Kom., selaku Dosen Pembimbing I yang telah memberikan bimbingan, arahan, masukan, serta motivasi kepada penulis dengan penuh kesabaran selama proses penyusunan skripsi ini.
5. Nurizal Dwi Priandani, M.Kom., selaku Dosen Pembimbing II yang telah memberikan bimbingan, masukan, arahan, serta saran yang berharga kepada penulis dalam proses penyusunan dan penyempurnaan skripsi ini.
6. Dr. M. Ainul Yaqin, M.Kom., selaku Dosen Penguji I, dan Tri Mukti Lestari, M.Kom., selaku Dosen Penguji II, atas saran, kritik, dan masukan yang berharga dalam penyempurnaan penelitian serta penyusunan skripsi ini.

7. Dr. Agung Teguh Wibowo Almais, M.T., selaku Dosen Wali yang telah memberikan bimbingan, arahan, masukan, serta motivasi kepada penulis dengan penuh kesabaran selama menjalani masa perkuliahan.
8. Seluruh dosen dan staf Fakultas Sains dan Teknologi, khususnya Program Studi Teknik Informatika, yang telah menjadi bagian dari perjalanan akademik penulis melalui ilmu, pengalaman, serta berbagai bantuan yang diberikan selama masa perkuliahan.
9. Teruntuk orang-orang yang paling penulis cintai dan sayangi, Ibu, Ayah, Kakak, Adik, Nenek, Kakek, Tante, Om. Terima kasih telah merawat, membimbing, mendukung, dan menyayangi penulis sejak kecil hingga dewasa. Terima kasih atas segala pengorbanan, doa, perhatian, serta kasih sayang yang telah diberikan. Kalian selalu menjadi bagian terpenting dalam hidup penulis, sumber kekuatan, dan penyemangat dalam setiap langkah yang dijalani.
10. Prof. Dr. H. Achmad Khudori Soleh, M.Ag., dan Ibu Erik Sabti Rahmawati, M.A., M.Ag., yang telah membimbing, mendidik, serta memberikan ilmu dan nasihat kepada penulis selama berada di pondok. Terima kasih atas kesabaran, keteladanan, doa, serta arahan yang telah diberikan. Semoga segala ilmu dan kebaikan yang telah diberikan menjadi amal jariyah dan selalu mendapatkan keberkahan dari Allah SWT.
11. Teruntuk sahabat-sahabat terbaik penulis, Nurul Aziza Kusuma Dewi, Annisa Ayu Permadani, Salsabila Ramadanti Nuraini, Ferina Putri Soedjono, dan Jinan Naurah, Iqlima Rahmafitri Karindah. Terima kasih atas doa, dukungan, bantuan, serta kebersamaan yang telah diberikan selama masa perkuliahan.

hingga penyusunan skripsi ini. Terima kasih telah menjadi tempat berbagi cerita, tawa, dan semangat di setiap proses perjuangan. Semoga persahabatan ini selalu terjaga dan menjadi kenangan indah yang tidak terlupakan.

12. Teman-teman Teknik Informatika angkatan 2021 (ASTER), terima kasih atas kebersamaan, semangat, dan dukungan selama menjalani masa perkuliahan. Semoga seluruh anggota ASTER senantiasa diberikan kemudahan, kesuksesan, dan keberkahan dalam setiap langkah ke depan. Bagi teman-teman yang masih berjuang menyelesaikan tugas akhir, semoga diberikan kelancaran dan dapat segera menyusul meraih gelar yang diimpikan.

13. Keluarga Pondok Pesantren Al-Azkiya' dan kamar B2, Mbak Rosyida, Mbak Fadila, Mbak Irma, Mbak Alifa, Faizah, Hulud, dan Azka. Terima kasih atas kebersamaan, doa, dukungan, motivasi, serta bantuan yang telah diberikan kepada penulis selama berada di pondok. Terima kasih telah menjadi teman berbagi cerita, tempat berkeluh kesah, dan bagian dari perjalanan hidup yang penuh makna. Semoga kebersamaan ini selalu menjadi kenangan baik dan hubungan silaturahmi tetap terjaga.

14. Teruntuk diri penulis sendiri, terima kasih telah bertahan, berjuang, dan tidak menyerah hingga sampai di titik ini. Terima kasih telah melewati berbagai tantangan, rasa lelah, dan keraguan selama proses perkuliahan hingga penyusunan skripsi. Semoga segala usaha yang telah dilakukan menjadi awal dari langkah-langkah baik di masa depan.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna dan tidak terlepas dari berbagai kekurangan, baik dalam penyajian maupun isi. Oleh

karena itu, penulis mengharapkan kritik dan saran yang membangun sebagai bahan evaluasi dan perbaikan di masa mendatang.

Penulis berharap skripsi ini dapat memberikan manfaat bagi pembaca serta menjadi kontribusi dalam pengembangan ilmu pengetahuan, khususnya pada bidang pengolahan citra digital dan klasifikasi tanaman herbal berdasarkan citra daun menggunakan metode Multiclass Support Vector Machine.

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Malang, 29 Juni 2026

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xii
DAFTAR GAMBAR.....	xiv
DAFTAR TABEL	xv
ABSTRAK	xvi
ABSTRACT	xvii
مستخلص البحث	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
BAB II STUDI PUSTAKA	5
2.1 Penelitian Terdahulu	5
2.2 Tanaman Herbal dan Karakteristik daun.....	7
2.3 Pengolahan Citra Digital	8
2.4 <i>Hue, Saturation, Value</i> (HSV)	8
2.5 <i>Gray Level Co-occurrence Matrix</i> (GLCM).....	11
2.6 <i>Hu Moment</i>	15
2.7 Support Vector Machine (SVM).....	20
2.8 Kombinasi Fitur Visual pada Klasifikasi Citra Daun.....	23
2.9 Pengenalan Cita Luar Kelas	24
BAB III METODOLOGI PENELITIAN	26
3.1 Desain Alur Penelitian	26
3.1.1 Pengumpulan Data	26
3.1.2 Desain Sistem.....	28
3.1.3 Perhitungan Manual	34
3.1.4 Skenario Pengujian.....	39
3.2 Implementasi	41
3.2.1 Persiapan Dataset	41
3.2.2 Preprocessing dan Segmentasi Citra	42
3.2.3 Ekstraksi Fitur Citra	43
3.2.4 Pembagian Data Training dan Testing.....	44
3.2.5 Pelatihan Model Multiclass SVM	45
3.2.6 Implementasi Evaluasi Model.....	46
3.2.7 Uji Manual Citra Daun.....	47
BAB IV HASIL DAN PEMBAHASAN	50
4.1 Hasil	50

4.1.1 Pelatihan dan Evaluasi Model SVM	50
4.1.2 Pengujian Manual Berdasarkan Skenario	51
4.2 Pembahasan.....	54
4.2.1 Kinerja Model pada Data Testing	54
4.2.2 Peran Fitur Warna Tekstur dan Bentuk.....	56
4.2.3 Pengujian Manual dan Penolakan Citra Luar Kelas	58
4.2.4 Analisis Mekanisme Penolakan Citra Luar Kelas.....	59
4.2.5 Evaluasi Kinerja dan Keterbatasan Sistem	62
4.2 Integrasi Islam.....	64
BAB V KESIMPULAN DAN SARAN	68
5.1 Kesimpulan	68
5.2 Saran.....	68
DAFTAR PUSTAKA.....	70
LAMPIRAN.....	72

DAFTAR GAMBAR

Gambar 3. 1 Desain alur penelitian.....	26
Gambar 3. 2 Desain Sistem.....	28
Gambar 3. 3 Kode program persiapan dataset	41
Gambar 3. 4 Output persiapan dataset	42
Gambar 3. 5 Kode program preprocessing dan segmentasi citra.....	42
Gambar 3. 6 Output preprocessing dan segmentasi citra.....	43
Gambar 3. 7 Kode program ekstraksi fitur citra	44
Gambar 3. 8 Output ekstraksi fitur citra.....	44
Gambar 3. 9 Kode program pembagian data training dan testing.....	44
Gambar 3. 10 Output pembagian data training dan testing.....	45
Gambar 3. 11 Kode program pelatihan model Multiclass SVM.....	46
Gambar 3. 12 Output pelatihan model Multiclass SVM.....	46
Gambar 3. 13 Kode program evaluasi model.....	47
Gambar 3. 14 Output evaluasi model.....	47
Gambar 3. 15 Kode program uji manual citra daun.....	48
Gambar 3. 16 Output uji manual citra daun	48
Gambar 4. 1 Classification report data testing	51

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu	5
Tabel 3. 1 Distribusi Citra Daun Herbal Penelitian	27
Tabel 3. 2 Nilai fitur citra uji daun jambu biji	35
Tabel 3. 3 Perhitungan jarak, threshold, dan kemiripan citra uji	38
Tabel 3. 4 Keputusan akhir pada citra uji	39
Tabel 3. 5 Variasi citra pada pengujian manual	40
Tabel 3. 6 Skenario pengujian citra daun	40
Tabel 4. 1 Hasil pelatihan model SVM	50
Tabel 4. 2 Ringkasan hasil pengujian manual berdasarkan skenario	51
Tabel 4. 3 Hasil Deteksi Citra Target	52
Tabel 4. 4 Ringkasan 24 Citra Uji Manual	52
Tabel 4. 5 Citra Luar Kelas yang Masih Terdeteksi	53
Tabel 4. 6 Ringkasan Analisis Kinerja Uji Manual	61

ABSTRAK

Devi, Vinka Rosalia Fatimah. 2026. **Klasifikasi Tanaman Herbal Berdasarkan Citra Daun Menggunakan Metode Multiclass Support Vector Machine**. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Totok Chamidy, M.Kom. (II) Nurizal Dwi Priandani, M.Kom.

Kata kunci: klasifikasi daun herbal, citra daun, HSV, GLCM, Hu Moment, Multiclass SVM.

Tanaman herbal masih banyak digunakan oleh masyarakat Indonesia, sehingga proses identifikasi jenis tanaman perlu dilakukan secara tepat. Kesalahan identifikasi dapat terjadi karena beberapa daun memiliki kemiripan warna, tekstur, dan bentuk. Penelitian ini bertujuan menerapkan metode *Multiclass Support Vector Machine kernel Radial Basis Function* untuk mengklasifikasikan tanaman herbal berdasarkan citra daun. Data penelitian terdiri atas 400 citra daun dari empat kelas, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih. Tahap penelitian meliputi pengumpulan data, *resize* citra menjadi 224 x 224 piksel, segmentasi daun berbasis HSV, ekstraksi fitur warna HSV, fitur tekstur GLCM, fitur bentuk berbasis kontur dan *Hu Moment*, pembagian data training dan testing dengan rasio 80:20, pelatihan model menggunakan StandardScaler dan GridSearchCV, evaluasi model, serta pengujian manual citra daun. Sistem juga dilengkapi mekanisme penolakan citra luar kelas menggunakan kombinasi probabilitas SVM, jarak fitur terhadap centroid, dan nilai kemiripan. Hasil penelitian menunjukkan parameter terbaik $C = 10$ dan $\gamma = 0,1$. Model memperoleh akurasi validasi sebesar 98,75% dan akurasi data testing sebesar 96,25%. Pada pengujian manual, sistem berhasil mendeteksi 4 dari 4 citra target dan menolak 17 dari 20 citra luar kelas. Keberhasilan uji manual mencapai 87,50%, sedangkan kemampuan penolakan citra luar kelas mencapai 85,00%. Hasil tersebut menunjukkan bahwa kombinasi fitur warna, tekstur, bentuk, dan Multiclass SVM kernel RBF dapat digunakan untuk klasifikasi daun herbal dengan kinerja yang baik.

ABSTRACT

Devi, Vinka Rosalia Fatimah. 2026. **Herbal Plant Classification Based on Leaf Images Using the Multiclass Support Vector Machine Method**. Undergraduate Thesis. Department of Informatics Engineering, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisors: (I) Dr. Totok Chamidy, M.Kom. (II) Nurizal Dwi Priandani, M.Kom.

Keywords: herbal leaf classification, leaf image, HSV, GLCM, Hu Moment, Multiclass SVM.

Herbal plants are still widely used by Indonesian people; therefore, accurate plant identification is necessary because identification errors may occur due to similarities in leaf color, texture, and shape. This study aims to apply the Multiclass Support Vector Machine method with the Radial Basis Function kernel to classify herbal plants based on leaf images. The dataset consisted of 400 leaf images from four classes, namely guava leaves, turmeric leaves, papaya leaves, and betel leaves. The research stages included data collection, image resizing to 224×224 pixels, HSV-based leaf segmentation, HSV color feature extraction, GLCM texture feature extraction, contour-based shape feature extraction, and Hu Moment feature extraction, followed by data splitting into training and testing sets with an 80:20 ratio, model training using StandardScaler and GridSearchCV, model evaluation, and manual image testing. The system also incorporated an out-of-class image rejection mechanism using a combination of SVM probability, feature distance to centroid, and similarity score. The results showed that the best parameters were $C = 10$ and $\gamma = 0.1$, with the model achieving a validation accuracy of 98.75% and a testing accuracy of 96.25%. In manual testing, the system successfully identified 4 out of 4 target images and rejected 17 out of 20 out-of-class images, resulting in a success rate of 87.50%, while the out-of-class rejection performance reached 85.00%. These findings indicate that the combination of color, texture, and shape features with a Multiclass Support Vector Machine using the RBF kernel can effectively be used for herbal leaf classification with high performance.

مستخلص البحث

ديفي، فينكا روزاليا فاطمة. 2026. تصنيف النباتات العشبية بناءً على صور الأوراق باستخدام طريقة آلة متجه الدعم متعددة الفئات. رسالة جامعية. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانغ. المشرفان: (الأول) د. توتوك خاميدي، ماجستير في الحاسوب. (الثاني) نوريزال دوي بريانداني، ماجستير في الحاسوب.

الكلمات المفتاحية: تصنيف أوراق النباتات العشبية، صورة الورقة، HSV، GLCM، Hu Moment، Multiclass SVM.

لا تزال النباتات العشبية تُستخدم بكثرة من قبل المجتمع الإندونيسي، لذلك يجب أن تتم عملية تحديد نوع النبات بدقة، وقد تحدث أخطاء في التعرف بسبب تشابه بعض الأوراق في اللون واللمس والشكل، وتهدف هذه الدراسة إلى تطبيق طريقة آلة متجه الدعم متعددة الفئات باستخدام نواة دالة الأساس الشعاعي لتصنيف النباتات العشبية بناءً على صور الأوراق، وتتكون بيانات الدراسة من 400 صورة لأوراق من أربع فئات، وهي أوراق الجوافة وأوراق الكركم وأوراق البابايا وأوراق التنبول، وتشمل مراحل البحث جمع البيانات، وتغيير حجم الصورة إلى 224×224 بكسل، وتقسيم الورقة اعتمادًا على HSV، واستخراج خصائص اللون باستخدام HSV، وخصائص النسيج باستخدام GLCM، وخصائص الشكل المعتمدة على المحيط و Hu Moment، ثم تقسيم البيانات إلى بيانات تدريب واختبار بنسبة 80:20، وتدريب النموذج باستخدام StandardScaler و GridSearchCV، وتقييم النموذج، بالإضافة إلى الاختبار اليدوي لصور الأوراق، كما زُود النظام بآلية لرفض الصور الخارجة عن الفئات باستخدام مزيج من احتمالية SVM ومسافة الخصائص إلى المركز وقيمة التشابه، وقد أظهرت نتائج الدراسة أن أفضل المعلمات هي $C = 10$ و $\gamma = 0.1$ ، وحقق النموذج دقة تحقق بلغت 98.75% ودقة اختبار بلغت 96.25%، وفي الاختبار اليدوي نجح النظام في اكتشاف 4 من أصل 4 صور مستهدفة ورفض 17 من أصل 20 صورة خارجة عن الفئات، وبلغت نسبة نجاح الاختبار اليدوي 87.50% بينما بلغت قدرة النظام على رفض الصور الخارجة عن الفئات 85.00%، وتشير النتائج إلى أن دمج خصائص اللون والنسيج والشكل مع طريقة آلة متجه الدعم متعددة الفئات بنواة RBF يمكن استخدامه لتصنيف أوراق النباتات العشبية بكفاءة جيدة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penggunaan tanaman herbal masih menjadi bagian penting dalam kehidupan masyarakat Indonesia. Tanaman herbal digunakan untuk menjaga kesehatan, membantu pemulihan, dan menjadi pilihan pendamping pengobatan modern. Pradipta dkk. (2023) melaporkan bahwa 27,1% pasien penyakit kronis di Indonesia menggunakan pengobatan tradisional dalam manajemen kesehatannya. Temuan ini menunjukkan bahwa tanaman herbal masih memiliki peran nyata dalam praktik kesehatan Masyarakat (Pradipta dkk., 2023).

Meningkatnya penggunaan tanaman herbal perlu diikuti dengan kemampuan identifikasi yang tepat. Kesalahan mengenali tanaman dapat membuat manfaat yang diharapkan tidak tercapai. Pada beberapa kondisi, kesalahan tersebut juga dapat meningkatkan risiko penggunaan tanaman yang tidak sesuai. Masalah ini muncul karena beberapa tanaman memiliki bentuk daun, warna, tekstur, dan pola tulang daun yang hampir sama.

Risiko kesalahan identifikasi tidak hanya terjadi pada pemakaian langsung di masyarakat. Ichim (2019) menjelaskan bahwa autentikasi herbal menjadi penting karena bahan herbal dapat mengalami substitusi, kontaminasi, atau kesalahan label (Ichim, 2019). Orhan dkk. (2024) juga melaporkan bahwa 818 dari 2.995 sampel bahan herbal populer mengalami pemalsuan atau kesalahan pelabelan (Orhan dkk.,

2024). Data tersebut menunjukkan bahwa autentikasi tanaman herbal perlu dilakukan secara teliti agar kesalahan identitas dapat dikurangi.

Identifikasi tanaman secara manual masih bergantung pada pengalaman pengamat. Wäldchen dkk. (2022) menunjukkan bahwa kemampuan manusia dalam mengenali karakter morfologi tanaman masih memiliki peluang kesalahan, terutama pada pengamat yang belum berpengalaman. Kondisi ini membuat sistem bantu berbasis citra menjadi relevan untuk dikembangkan .

Pengolahan citra digital dapat membantu membaca karakter visual daun secara lebih terukur. Citra daun dapat diproses untuk memperoleh fitur warna, tekstur, dan bentuk. Fitur warna dapat menggambarkan karakter warna daun, fitur tekstur dapat menggambarkan pola permukaan daun, sedangkan fitur bentuk dapat menggambarkan geometri daun. Ketiga kelompok fitur tersebut dapat diubah menjadi data numerik agar dapat dibaca oleh algoritma klasifikasi.

Support Vector Machine (SVM) merupakan salah satu metode klasifikasi yang banyak digunakan pada data fitur citra. SVM bekerja dengan membentuk batas pemisah terbaik antar kelas. Pada data citra daun, pola fitur tidak selalu dapat dipisahkan secara linear. Oleh karena itu, kernel *Radial Basis Function* (RBF) digunakan karena mampu menangani pola data yang lebih kompleks.

Penelitian ini menerapkan Multiclass SVM kernel RBF untuk mengklasifikasikan empat jenis daun herbal, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih. Sistem juga menambahkan mekanisme penolakan citra luar kelas melalui kombinasi probabilitas SVM, jarak fitur terhadap centroid, dan

nilai kemiripan. Dengan mekanisme ini, sistem tidak langsung menerima setiap citra sebagai salah satu kelas data latih.

Dimensi etis dan spiritual juga memperkuat pentingnya penelitian ini. Al-Qur'an menjelaskan bahwa tumbuh-tumbuhan merupakan karunia Allah yang perlu dipikirkan dan dimanfaatkan secara bijak. Dalam QS. An-Nahl ayat 11 Allah berfirman:

يُنَبِّئُكُمْ بِهِ الْزَّرْعَ وَالزَّيْتُونَ وَالنَّخِيلَ وَالْأَعْنَابَ وَمِنْ كُلِّ الثَّمَرَاتِ إِنَّ فِي ذَلِكَ لَآيَةً لِّقَوْمٍ يَتَفَكَّرُونَ ﴿١١﴾

Artinya :

“Dengan (air hujan) itu Dia menumbuhkan untuk kamu tanam-tanaman, zaitun, kurma, anggur dan segala macam buah-buahan. Sungguh, pada yang demikian itu benar-benar terdapat tanda (kebesaran Allah) bagi orang yang berpikir”. (QS. An-Nahl ayat 11)

Ayat tersebut menunjukkan bahwa keberagaman tumbuhan merupakan tanda kebesaran Allah yang perlu dikaji dan dimanfaatkan untuk kebaikan manusia. Menurut Tafsir al-Misbah karya M. Quraish Shihab, keberagaman tumbuhan menjadi dorongan bagi manusia untuk berpikir, meneliti, dan memanfaatkannya secara optimal. Imam al-Qurtubi juga menjelaskan bahwa penyebutan berbagai jenis tanaman menunjukkan luasnya manfaat tumbuhan, baik sebagai sumber pangan maupun sebagai bahan pengobatan.

1.2 Pernyataan Masalah

Berdasarkan latar belakang tersebut, pernyataan masalah dalam penelitian ini adalah: bagaimana kinerja metode Multiclass Support Vector Machine dengan kernel RBF dalam mengklasifikasikan tanaman herbal berdasarkan citra daun?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

- a. Penelitian ini menggunakan empat kelas daun herbal, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih.
- b. Dataset utama berjumlah 400 citra, dengan 100 citra pada setiap kelas.
- c. Fitur citra yang digunakan terdiri atas fitur warna HSV, fitur tekstur GLCM, dan fitur bentuk berbasis kontur serta Hu Moments.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah untuk mengetahui dan menganalisis kinerja metode *Multiclass Support Vector Machine* dengan *kernel Radial Basis Function* (RBF) dalam mengklasifikasikan tanaman herbal berdasarkan citra daun.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

- a. Bagi masyarakat, penelitian ini dapat menjadi alat bantu awal untuk mengenali daun herbal sehingga risiko kesalahan identifikasi dapat dikurangi.
- b. Bagi peneliti, penelitian ini dapat menjadi referensi penerapan Multiclass SVM pada klasifikasi citra daun herbal.
- c. Bagi institusi, penelitian ini dapat menambah referensi ilmiah di bidang pengolahan citra dan machine learning.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terdahulu

Dalam lima tahun terakhir, berbagai penelitian telah dilakukan untuk mengembangkan metode klasifikasi tanaman herbal maupun tanaman obat berbasis citra daun. Berikut adalah ringkasan penelitian terdahulu yang relevan dengan penelitian ini:

Tabel 2. 1 Penelitian Terdahulu

No	Penulis	Topik	Metode	Hasil Utama	Perbedaan dengan Penelitian Ini
1.	(Prayoga dkk., 2023)	Klasifikasi daun katuk dan kelor	KNN dan SVM dengan fitur Fourier Descriptor	SVM memperoleh akurasi tinggi pada skenario citra terang dan gelap.	Penelitian ini memakai empat kelas daun herbal, fitur HSV, GLCM, bentuk, dan SVM RBF.
2.	(Meo dkk., 2024)	Klasifikasi tanaman herbal	SVM dengan fitur GLCM	Akurasi terbaik diperoleh pada kernel polynomial sebesar 83%.	Penelitian ini menambahkan fitur warna, fitur bentuk, dan mekanisme penolakan citra luar kelas.
3.	(Agus Supriyanto dkk., 2023)	Klasifikasi penyakit daun kopi robusta	SVM dengan ekstraksi fitur GLCM	Kernel RBF Gaussian memperoleh akurasi 97,5%.	Penelitian ini berfokus pada jenis daun herbal, bukan penyakit daun.
4.	(Purnawansyah dkk., 2023)	Klasifikasi daun herbal	GLCM-SVM dan GLCM-CNN	Kombinasi GLCM-SVM memperoleh akurasi 96% pada uji intensitas gelap.	Penelitian ini menggabungkan warna, tekstur, dan bentuk pada empat kelas herbal.
5.	(Amriana dkk., 2025)	Optimasi klasifikasi tanaman herbal	Hybrid PSO-SVM	PSO-SVM memperoleh akurasi 98% dan SVM dasar memperoleh akurasi 91%.	Penelitian ini memakai GridSearchCV untuk mencari C dan gamma terbaik pada SVM RBF.

Berdasarkan Tabel 2.1, penelitian mengenai klasifikasi citra daun dalam lima tahun terakhir menunjukkan bahwa algoritma SVM masih banyak digunakan karena mampu membaca pola fitur visual dengan baik. Perbedaan utama antar penelitian umumnya terletak pada jenis fitur yang dipakai, jumlah kelas yang diuji, serta tujuan klasifikasinya, apakah untuk membedakan jenis daun, mendeteksi penyakit, atau mengoptimalkan performa model.

Pada penelitian sebelumnya, Prayoga dkk. (2023) lebih menekankan fitur bentuk melalui Fourier Descriptor, sehingga fokus utamanya ada pada kontur daun. Meo dkk. (2024) menunjukkan bahwa SVM dengan fitur GLCM dapat digunakan untuk klasifikasi tanaman herbal, tetapi performanya masih dipengaruhi oleh pemilihan kernel. Purnawansyah dkk. (2023) memperlihatkan bahwa kombinasi GLCM dan SVM tetap kompetitif ketika dibandingkan dengan pendekatan CNN pada klasifikasi daun herbal. Ramli dkk. (2025) menegaskan bahwa kombinasi HSV dan GLCM dapat memperkuat pembacaan warna dan tekstur pada citra daun, sedangkan Amriana dkk. (2025) menunjukkan bahwa pengaturan parameter yang tepat dapat meningkatkan kinerja SVM secara signifikan.

Di luar informasi dalam tabel 2.1, penelitian-penelitian tersebut juga memperlihatkan bahwa belum banyak studi yang secara khusus menambahkan mekanisme penolakan citra luar kelas pada sistem klasifikasi daun herbal. Sebagian besar penelitian berhenti pada tahap pengukuran akurasi, precision, recall, dan f1-score. Oleh karena itu, penelitian ini tidak hanya mengadopsi penggunaan fitur warna, tekstur, dan bentuk, tetapi juga menambahkan pemeriksaan probabilitas,

jarak fitur terhadap centroid, dan nilai kemiripan agar sistem lebih selektif saat menerima citra uji.

2.2 Tanaman Herbal dan Karakteristik daun

Tanaman herbal adalah tanaman yang dimanfaatkan masyarakat untuk menjaga kesehatan atau membantu proses pengobatan tradisional. Pada citra daun, karakter visual yang dapat diamati meliputi warna, bentuk, ukuran, tekstur permukaan, tepi daun, serta pola tulang daun. Daun jambu biji cenderung berbentuk elips dengan tulang daun menyirip. Daun kunyit memanjang dengan tulang daun utama yang jelas. Daun pepaya memiliki bentuk menjari dengan lekukan yang dalam. Daun sirih berbentuk menyerupai hati dengan permukaan yang relatif mengilap. Perbedaan karakter tersebut menjadi dasar pemilihan fitur pada sistem.

Karakteristik daun penting digunakan sebagai dasar identifikasi karena daun merupakan bagian tanaman yang relatif mudah diperoleh dan tidak selalu memerlukan perusakan tanaman secara keseluruhan. Dalam pengolahan citra, warna daun dapat mewakili kondisi visual umum, tekstur daun dapat menggambarkan pola permukaan, sedangkan bentuk daun dapat menunjukkan ciri morfologi yang lebih khas. Kombinasi ketiga karakteristik tersebut membuat sistem klasifikasi dapat membaca objek daun secara lebih lengkap (Lubis dkk., 2024).

Pada konteks tanaman herbal, ketepatan membaca karakter daun menjadi penting karena beberapa jenis tanaman dapat mempunyai warna atau bentuk yang sekilas tampak mirip. Oleh sebab itu, pendekatan berbasis citra yang memanfaatkan warna, tekstur, dan bentuk lebih sesuai dibandingkan pendekatan yang hanya mengandalkan satu jenis fitur saja. Pendekatan ini juga sejalan dengan penelitian

klasifikasi daun herbal terbaru yang menekankan pentingnya penggabungan beberapa fitur visual agar sistem lebih stabil pada kondisi data yang bervariasi.

2.3 Pengolahan Citra Digital

Pengolahan citra digital digunakan untuk menyiapkan citra sebelum masuk ke tahap klasifikasi. Pada penelitian ini, citra diproses melalui perubahan ukuran, segmentasi daun, dan ekstraksi fitur. Perubahan ukuran membuat semua citra memiliki dimensi yang sama. Segmentasi memisahkan objek daun dari latar belakang. Ekstraksi fitur mengubah informasi visual menjadi angka yang dapat dipelajari oleh model.

2.4 *Hue, Saturation, Value* (HSV)

Hue, Saturation, Value (HSV) merupakan ruang warna yang memisahkan informasi warna menjadi tiga komponen utama, yaitu hue, saturation, dan value. Hue menunjukkan jenis warna, saturation menunjukkan tingkat kejenuhan warna, sedangkan value menunjukkan tingkat kecerahan warna. Pada citra daun, HSV sering digunakan karena warna objek dapat dibaca lebih jelas dibandingkan RGB, terutama ketika citra dipengaruhi oleh cahaya, bayangan, atau kondisi kamera. Ruang warna HSV juga banyak digunakan dalam pengolahan citra digital karena dapat membantu proses segmentasi dan ekstraksi fitur warna (Gonzalez & Woods, 2017).

Sebelum nilai HSV dihitung, nilai RGB pada sebuah piksel perlu dinormalisasi terlebih dahulu. Normalisasi dilakukan agar nilai merah, hijau, dan biru berada pada rentang 0 sampai 1. Jika nilai RGB asli berada pada rentang 0 sampai 255, maka proses normalisasi dapat dituliskan sebagai berikut:

$$r = \frac{R}{255}, g = \frac{G}{255}, b = \frac{B}{255} \quad (2.1)$$

Keterangan:

R = nilai merah pada piksel

G = nilai hijau pada piksel

B = nilai biru pada piksel

r = nilai merah setelah dinormalisasi

g = nilai hijau setelah dinormalisasi

b = nilai biru setelah dinormalisasi

Setelah nilai RGB dinormalisasi, langkah berikutnya adalah mencari nilai terbesar, nilai terkecil, dan selisih antara keduanya. Nilai ini digunakan sebagai dasar untuk menghitung Hue, Saturation, dan Value. Perhitungannya dapat dituliskan sebagai berikut:

$$C_{max} = \max(r, g, b) \quad (2.2)$$

$$C_{min} = \min(r, g, b) \quad (2.3)$$

$$\Delta = C_{max} - C_{min} \quad (2.4)$$

Keterangan:

C_{max} = nilai terbesar dari r, g , dan b

C_{min} = nilai terkecil dari r, g , dan b

Δ = selisih antara C_{max} dan C_{min}

Komponen pertama dalam HSV adalah Hue. Hue digunakan untuk menunjukkan jenis warna pada sebuah piksel, misalnya merah, hijau, biru, atau warna lainnya. Nilai Hue dihitung berdasarkan komponen warna RGB yang memiliki nilai paling besar. Rumus Hue dapat dituliskan sebagai berikut:

$$H = \begin{cases} 0, & \text{jika } \Delta = 0 \\ 60^\circ \times \left(\frac{g-b}{\Delta} \right) \text{ m } 6, & \text{jika } C_{max} = r \\ 60^\circ \times \left(\frac{b-r}{\Delta} + 2 \right), & \text{jika } C_{max} = g \\ 60^\circ \times \left(\frac{r-g}{\Delta} + 4 \right), & \text{jika } C_{max} = b \end{cases} \quad (2.5)$$

Keterangan:

H = nilai Hue atau jenis warna

Δ = selisih antara nilai warna terbesar dan terkecil

C_{max} = nilai warna terbesar dari r, g , dan b

r = nilai merah setelah normalisasi

g = nilai hijau setelah normalisasi

b = nilai biru setelah normalisasi

Persamaan (2.5) menunjukkan bahwa nilai Hue bergantung pada warna yang paling dominan dalam sebuah piksel. Jika nilai merah paling besar, maka rumus Hue menggunakan selisih antara hijau dan biru. Jika nilai hijau paling besar, maka rumus Hue menggunakan selisih antara biru dan merah. Jika nilai biru paling besar, maka rumus Hue menggunakan selisih antara merah dan hijau. Dengan cara ini, sistem dapat mengetahui jenis warna utama dari sebuah piksel.

Komponen kedua adalah Saturation. Saturation menunjukkan tingkat kejenuhan atau kemurnian warna. Jika nilai saturation tinggi, maka warna terlihat lebih kuat. Sebaliknya, jika nilai saturation rendah, maka warna terlihat lebih pucat atau mendekati abu-abu. Rumus Saturation dapat dituliskan sebagai berikut:

$$S = \begin{cases} 0, & \text{jika } C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & \text{jika } C_{max} \neq 0 \end{cases} \quad (2.6)$$

Keterangan:

S = nilai Saturation atau tingkat kejenuhan warna

Δ = selisih antara C_{max} dan C_{min}

C_{max} = nilai terbesar dari r , g , dan b

Persamaan (2.6) menjelaskan bahwa saturation dihitung dari perbandingan antara selisih warna dan nilai warna terbesar. Jika nilai C_{max} sama dengan 0, maka piksel tidak memiliki warna yang jelas sehingga nilai saturation dibuat 0. Pada citra daun, saturation dapat membantu membedakan daun yang memiliki warna hijau pekat dengan daun yang warnanya lebih pucat.

Komponen ketiga adalah Value. Value menunjukkan tingkat kecerahan dari sebuah piksel. Nilai value diperoleh dari nilai terbesar antara komponen merah,

hijau, dan biru yang telah dinormalisasi. Rumus Value dapat dituliskan sebagai berikut:

$$V = C_{max} \quad (2.7)$$

Keterangan:

V = nilai Value atau tingkat kecerahan warna

C_{max} = nilai terbesar dari r , g , dan b

Persamaan (2.7) menunjukkan bahwa semakin besar nilai C_{max} , maka semakin terang warna piksel tersebut. Sebaliknya, semakin kecil nilai C_{max} , maka piksel akan terlihat semakin gelap. Dalam citra daun, value berguna untuk membaca tingkat terang dan gelap pada permukaan daun akibat pencahayaan atau bayangan.

Secara sederhana, sebuah piksel dapat menghitung HSV dengan cara membaca nilai RGB terlebih dahulu, kemudian mengubah nilai tersebut ke rentang 0 sampai 1. Setelah itu, sistem mencari nilai warna terbesar, nilai warna terkecil, dan selisihnya. Nilai tersebut digunakan untuk menghitung Hue sebagai jenis warna, Saturation sebagai tingkat kejenuhan warna, dan Value sebagai tingkat kecerahan warna. Pada penelitian klasifikasi citra daun, nilai HSV dari banyak piksel daun kemudian dapat dirata-ratakan agar menjadi fitur warna yang digunakan oleh model klasifikasi.

2.5 Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) merupakan metode ekstraksi fitur tekstur yang digunakan untuk membaca hubungan antar piksel pada citra grayscale. GLCM bekerja dengan menghitung seberapa sering pasangan nilai intensitas piksel muncul pada jarak dan arah tertentu. Dengan cara ini, tekstur daun yang tampak halus, kasar, rapat, atau tidak merata dapat diubah menjadi nilai numerik yang dapat diproses oleh model klasifikasi. Metode GLCM pertama kali

diperkenalkan untuk menganalisis tekstur citra berdasarkan hubungan spasial antar piksel.

Pada penelitian ini, GLCM digunakan untuk mengambil fitur tekstur dari citra daun yang telah melalui tahap preprocessing dan segmentasi. Citra daun terlebih dahulu diubah ke bentuk grayscale agar setiap piksel hanya memiliki satu nilai intensitas. Setelah itu, sistem menghitung pasangan piksel berdasarkan jarak dan sudut tertentu. Pada citra daun, GLCM membantu membaca pola permukaan daun, misalnya tingkat kehalusan, kekasaran, dan variasi intensitas pada permukaan daun. Penggunaan GLCM juga banyak diterapkan pada penelitian klasifikasi citra daun karena mampu menangkap ciri tekstur yang sulit dibedakan secara langsung oleh mata manusia (Johari dkk., 2025).

Sebelum menghitung fitur tekstur, matriks GLCM perlu dinormalisasi terlebih dahulu. Normalisasi dilakukan agar nilai pada matriks berubah menjadi peluang kemunculan pasangan piksel. Rumus normalisasi GLCM dapat dituliskan sebagai berikut:

$$P(i, j) = \frac{M(i, j)}{\sum_i \sum_j M(i, j)} \quad (2.8)$$

Keterangan:

$P(i, j)$ = peluang kemunculan pasangan piksel dengan intensitas i dan j

$M(i, j)$ = jumlah kemunculan pasangan piksel dengan intensitas i dan j

i = nilai intensitas piksel pertama

j = nilai intensitas piksel kedua

Persamaan (2.8) menjelaskan bahwa nilai GLCM dihitung berdasarkan jumlah kemunculan pasangan piksel tertentu, kemudian dibagi dengan seluruh jumlah pasangan piksel. Hasilnya berupa nilai peluang. Nilai inilah yang digunakan

untuk menghitung fitur tekstur seperti contrast, dissimilarity, homogeneity, ASM, energy, dan correlation.

Fitur pertama adalah contrast. Contrast digunakan untuk mengukur tingkat perbedaan intensitas antar piksel yang berdekatan. Jika nilai contrast tinggi, maka citra memiliki perbedaan gelap dan terang yang lebih jelas. Rumus contrast dapat dituliskan sebagai berikut:

$$\text{Contrast} = \sum_i \sum_j (i - j)^2 P(i, j) \quad (2.9)$$

Keterangan:

Contrast = nilai perbedaan intensitas antar piksel

i = nilai intensitas piksel pertama

j = nilai intensitas piksel kedua

$P(i, j)$ = peluang kemunculan pasangan piksel i dan j

Fitur kedua adalah dissimilarity. Dissimilarity digunakan untuk mengukur tingkat ketidaksamaan antar piksel. Fitur ini mirip dengan contrast, tetapi perhitungannya menggunakan selisih mutlak. Rumus dissimilarity dapat dituliskan sebagai berikut:

$$\text{Dissimilarity} = \sum_i \sum_j |i - j| P(i, j) \quad (2.10)$$

Keterangan:

Dissimilarity = nilai ketidaksamaan antar piksel

$|i - j|$ = selisih mutlak antara intensitas piksel i dan j

$P(i, j)$ = peluang kemunculan pasangan piksel i dan j

Fitur ketiga adalah homogeneity. Homogeneity digunakan untuk mengukur tingkat keseragaman tekstur pada citra. Jika nilai homogeneity tinggi, maka pasangan piksel pada citra cenderung memiliki nilai intensitas yang mirip. Rumus homogeneity dapat dituliskan sebagai berikut:

$$\text{Homogeneity} = \sum_i \sum_j \frac{P(i,j)}{1 + (i-j)^2} \quad (2.11)$$

Keterangan:

Homogeneity = nilai keseragaman tekstur citra

$P(i,j)$ = peluang kemunculan pasangan piksel i dan j

$(i-j)^2$ = kuadrat selisih intensitas antara piksel i dan j

Fitur keempat adalah Angular Second Moment (ASM). ASM digunakan untuk mengukur kestabilan atau keteraturan pola tekstur pada citra. Semakin besar nilai ASM, maka pola tekstur pada citra cenderung semakin teratur. Rumus ASM dapat dituliskan sebagai berikut:

$$\text{ASM} = \sum_i \sum_j P(i,j)^2 \quad (2.12)$$

Keterangan:

ASM = nilai keteraturan pola tekstur

$P(i,j)^2$ = kuadrat peluang kemunculan pasangan piksel i dan j

Fitur kelima adalah energy. Energy merupakan akar dari nilai ASM. Fitur ini juga digunakan untuk menunjukkan keteraturan tekstur pada citra. Rumus energy dapat dituliskan sebagai berikut:

$$\text{Energy} = \sqrt{\text{ASM}} \quad (2.13)$$

Keterangan:

Energy = nilai energi atau kestabilan tekstur citra

ASM = nilai Angular Second Moment

Fitur keenam adalah correlation. Correlation digunakan untuk mengukur hubungan atau keterkaitan antara nilai intensitas piksel yang berdekatan. Rumus correlation dapat dituliskan sebagai berikut:

$$\text{Correlation} = \sum_i \sum_j \frac{(i - \mu_i)(j - \mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (2.14)$$

Keterangan:

Correlation = nilai hubungan antar intensitas piksel

μ_i = rata-rata nilai intensitas pada baris i
 μ_j = rata-rata nilai intensitas pada kolom j
 σ_i = standar deviasi intensitas pada baris i
 σ_j = standar deviasi intensitas pada kolom j
 $P(i, j)$ = peluang kemunculan pasangan piksel i dan j

Secara sederhana, cara kerja GLCM dapat dipahami sebagai proses menghitung hubungan antara satu piksel dengan piksel tetangganya. Sistem memilih satu piksel pada citra daun, kemudian melihat piksel lain di sebelah kanan, atas, bawah, atau diagonal sesuai sudut yang ditentukan. Pasangan nilai piksel tersebut dihitung jumlah kemunculannya. Dari hasil perhitungan pasangan piksel tersebut, sistem memperoleh nilai tekstur seperti contrast, dissimilarity, homogeneity, ASM, energy, dan correlation.

2.6 Hu Moment

Hu Moment merupakan metode ekstraksi fitur bentuk yang digunakan untuk mengenali bentuk objek pada citra. Metode ini pertama kali diperkenalkan oleh Hu sebagai fitur bentuk yang relatif tetap terhadap perubahan posisi, ukuran, dan rotasi objek (Ming-Kuei Hu, 1962). Dalam pengolahan citra digital, Hu Moment banyak digunakan karena mampu mengubah bentuk objek menjadi nilai numerik yang dapat diproses oleh model klasifikasi (Gonzalez & Woods, 2018).

Pada penelitian ini, Hu Moment digunakan untuk membaca bentuk daun dari hasil segmentasi. Setelah objek daun berhasil dipisahkan dari latar belakang, sistem mengambil kontur daun untuk memperoleh informasi bentuk. Fitur ini penting karena setiap jenis daun memiliki bentuk yang berbeda. Daun pepaya memiliki bentuk menjari, daun kunyit berbentuk memanjang, daun sirih berbentuk menyerupai hati, sedangkan daun jambu biji cenderung berbentuk elips. Penggunaan Hu Moment sebagai fitur bentuk juga masih relevan dalam penelitian

klasifikasi tanaman berbasis citra daun karena dapat membantu sistem mengenali pola bentuk tanaman secara lebih terukur (Hayatou Oumarou & Rismayanti, 2024).

Tahap awal dalam perhitungan Hu Moment adalah menghitung momen spasial. Momen spasial digunakan untuk membaca penyebaran piksel pada suatu objek. Rumus momen spasial dapat dituliskan sebagai berikut:

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad (2.15)$$

Keterangan:

m_{pq} = momen spasial dengan orde p dan q
 x = koordinat piksel pada sumbu horizontal
 y = koordinat piksel pada sumbu vertikal
 p = orde momen pada sumbu x
 q = orde momen pada sumbu y
 $f(x, y)$ = nilai piksel pada koordinat (x, y)

Persamaan (2.15) menunjukkan bahwa momen spasial dihitung berdasarkan posisi piksel dan nilai piksel pada objek. Pada citra biner hasil segmentasi, nilai $f(x, y)$ biasanya bernilai 1 untuk area objek daun dan 0 untuk area latar belakang. Dengan cara ini, sistem dapat mengetahui sebaran bentuk daun berdasarkan susunan pikselnya.

Setelah momen spasial diperoleh, langkah berikutnya adalah menentukan titik pusat objek atau centroid. Centroid digunakan sebagai titik tengah dari objek daun. Rumus centroid dapat dituliskan sebagai berikut:

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad (2.16)$$

$$\bar{y} = \frac{m_{01}}{m_{00}} \quad (2.17)$$

Keterangan:

$\bar{x}$ = koordinat pusat objek pada sumbu x
 $\bar{y}$ = koordinat pusat objek pada sumbu y
 m_{10} = momen spasial orde 1 pada sumbu x
 m_{01} = momen spasial orde 1 pada sumbu y
 m_{00} = jumlah seluruh piksel pada objek

Persamaan (2.16) dan Persamaan (2.17) digunakan untuk mencari titik pusat objek daun. Titik pusat ini penting karena perhitungan bentuk tidak hanya melihat posisi piksel, tetapi juga melihat jarak piksel terhadap pusat objek, jadi bentuk daun tetap dapat dibaca meskipun posisi daun pada citra berubah.

Tahap berikutnya adalah menghitung momen pusat. Momen pusat digunakan agar fitur bentuk lebih stabil terhadap perubahan posisi objek. Rumus momen pusat dapat dituliskan sebagai berikut:

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (2.18)$$

Keterangan:

μ_{pq} = momen pusat dengan orde p dan q
 x = koordinat piksel pada sumbu horizontal
 y = koordinat piksel pada sumbu vertikal
 $\bar{x}$ = koordinat pusat objek pada sumbu x
 $\bar{y}$ = koordinat pusat objek pada sumbu y
 $f(x, y)$ = nilai piksel pada koordinat (x, y)

Persamaan (2.18) menjelaskan bahwa setiap posisi piksel dihitung berdasarkan jaraknya terhadap titik pusat objek. Hal ini membuat fitur bentuk tidak terlalu dipengaruhi oleh letak objek di dalam citra. Misalnya, daun berada di tengah, agak ke kiri, atau agak ke kanan, bentuknya tetap dapat dibaca dengan lebih stabil.

Agar fitur bentuk tidak terlalu dipengaruhi oleh ukuran objek, momen pusat kemudian dinormalisasi. Tahap ini menghasilkan momen pusat ternormalisasi. Rumusnya dapat dituliskan sebagai berikut:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad (2.19)$$

$$\gamma = \frac{p + q}{2} + 1 \quad (2.20)$$

Keterangan:

η_{pq} = momen pusat ternormalisasi dengan orde p dan q
 μ_{pq} = momen pusat dengan orde p dan q
 μ_{00} = momen pusat orde nol atau luas objek

γ = faktor normalisasi
 p = orde momen pada sumbu x
 q = orde momen pada sumbu y

Persamaan (2.19) dan Persamaan (2.20) menunjukkan bahwa nilai momen pusat dibagi dengan faktor tertentu agar tidak terlalu dipengaruhi oleh ukuran objek jadi daun yang tampak besar atau kecil pada citra tetap dapat dibandingkan berdasarkan bentuknya.

Setelah momen pusat ternormalisasi diperoleh, sistem menghitung tujuh nilai Hu Moment. Tujuh nilai tersebut digunakan sebagai fitur bentuk karena mampu mewakili bentuk objek secara lebih stabil terhadap perubahan posisi, ukuran, dan rotasi. Dalam penelitian ini, tujuh nilai Hu Moment dihitung menggunakan fungsi HuMoments, kemudian digunakan sebagai bagian dari fitur bentuk daun. Secara ringkas, tujuh nilai Hu Moment dapat dituliskan sebagai berikut:

$$\Phi = [\phi_1, \phi_2, \phi_3, \phi_4, \phi_5, \phi_6, \phi_7] \quad (2.21)$$

Keterangan:

Φ = kumpulan fitur Hu Moment

$\phi_1, \phi_2, \phi_3, \phi_4, \phi_5, \phi_6, \phi_7$ = tujuh nilai Hu Moment

Persamaan (2.21) menunjukkan bahwa Hu Moment menghasilkan tujuh nilai utama yang dapat digunakan untuk membaca bentuk objek. Setiap nilai ϕ mewakili informasi bentuk dari sudut perhitungan yang berbeda. Pada penelitian ini, nilai Hu Moment digunakan untuk membantu sistem membedakan bentuk daun jambu biji, kunyit, pepaya, dan sirih. Fitur ini sesuai dengan konsep moment invariant yang diperkenalkan oleh Hu, yaitu fitur bentuk yang relatif tetap meskipun objek mengalami perubahan posisi, ukuran, atau rotasi (Ming-Kuei Hu, 1962).

Agar nilai Hu Moment lebih mudah digunakan dalam proses klasifikasi, nilai tersebut dapat diubah ke bentuk logaritmik. Transformasi ini dilakukan karena nilai Hu Moment sering memiliki rentang yang sangat kecil atau sangat besar. Bentuk transformasinya dapat dituliskan sebagai berikut:

$$H_k = -\text{sign}(\phi_k) \log_{10}(|\phi_k|) \quad (2.22)$$

Keterangan:

H_k = nilai Hu Moment ke- k setelah transformasi logaritmik

ϕ_k = nilai Hu Moment ke- k

k = urutan Hu Moment, yaitu 1,2,3, ...,7

$\text{sign}(\phi_k)$ = fungsi tanda dari nilai Hu Moment

$\log_{10}$ = logaritma berbasis 10

Persamaan (2.22) menjelaskan bahwa setiap nilai Hu Moment diubah ke bentuk logaritmik agar rentang nilainya lebih stabil. Dengan cara ini, nilai Hu Moment lebih mudah digabungkan dengan fitur lain, seperti area, perimeter, aspect ratio, circularity, dan eccentricity. Pada klasifikasi citra daun, fitur Hu Moment membantu model membaca bentuk daun secara lebih terukur, terutama ketika beberapa daun memiliki warna atau tekstur yang mirip. Selain itu, fitur bentuk juga dapat digunakan bersama fitur warna dan tekstur untuk meningkatkan kemampuan sistem dalam mengenali jenis tanaman herbal (Szturo, 2024)

Secara sederhana, cara kerja Hu Moment dapat dipahami sebagai proses membaca bentuk daun dari susunan pikselnya. Sistem terlebih dahulu melihat posisi setiap piksel daun, kemudian mencari titik pusat objek daun. Setelah itu, sistem menghitung penyebaran piksel terhadap titik pusat tersebut. Hasil akhirnya berupa tujuh angka Hu Moment yang mewakili bentuk daun. Angka-angka inilah yang digunakan oleh model klasifikasi untuk membantu membedakan jenis daun herbal.

2.7 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode pembelajaran terawasi yang digunakan untuk klasifikasi dan regresi. Pada tugas klasifikasi, SVM bekerja dengan mencari batas pemisah terbaik antara satu kelas dengan kelas lainnya. Batas pemisah tersebut disebut hyperplane. SVM berusaha membentuk hyperplane yang memiliki margin paling besar agar pemisahan antar kelas menjadi lebih optimal (Cortes & Vapnik, 1995), sedangkan penerapannya dalam klasifikasi citra daun masih banyak digunakan karena mampu mengolah fitur visual secara efektif (Meo dkk., 2024).

Tujuan utama dalam SVM adalah mencari hyperplane optimal yang memisahkan kelas dengan margin terbesar. Secara matematis, bentuk hyperplane dapat dituliskan sebagai berikut:

$$W^T x + b = 0 \quad (2.23)$$

Keterangan:

W = vektor bobot atau weight

W^T = transpose dari vektor bobot W

x = vektor fitur input

b = nilai bias

Persamaan (2.23) menunjukkan bahwa SVM menggunakan nilai fitur input, bobot, dan bias untuk membentuk garis atau bidang pemisah antar kelas. Nilai W berperan untuk menentukan arah hyperplane, sedangkan nilai b berfungsi untuk menggeser posisi hyperplane agar dapat memisahkan data dengan lebih tepat. Dalam penelitian ini, fitur input x dapat berupa gabungan fitur citra daun, seperti fitur warna, tekstur, dan bentuk.

Setelah hyperplane terbentuk, SVM menentukan kelas dari data baru dengan melihat posisi data tersebut terhadap hyperplane. Proses penentuan kelas untuk data baru dapat dituliskan sebagai berikut:

$$\text{Prediksi} = \text{sign}(W^T x_i + b) \quad (2.24)$$

Keterangan:

Prediksi = hasil kelas dari data uji

sign = fungsi tanda untuk menentukan posisi data terhadap hyperplane

W^T = transpose dari vektor bobot W

x_i = data uji ke- i

b = nilai bias

Persamaan (2.24) menjelaskan bahwa data uji x_i akan dihitung berdasarkan bobot dan bias yang telah diperoleh pada proses pelatihan. Fungsi sign digunakan untuk melihat apakah hasil perhitungan berada pada sisi positif atau sisi negatif dari hyperplane. Dengan cara ini, data dapat dimasukkan ke dalam kelas yang sesuai.

Margin menjadi bagian penting dalam SVM karena margin menunjukkan jarak antara hyperplane dengan titik data terdekat dari setiap kelas. Titik data terdekat tersebut disebut support vector. SVM berusaha memaksimalkan margin agar batas pemisah antar kelas menjadi lebih kuat. Secara sederhana, margin dapat dinyatakan sebagai berikut:

$$\text{Margin} = \frac{2}{\|W\|} \quad (2.25)$$

Keterangan:

Margin = jarak antara dua batas kelas terdekat

$\|W\|$ = panjang atau norma dari vektor bobot W

Persamaan (2.25) menunjukkan bahwa margin dipengaruhi oleh nilai bobot W . Jika nilai $\|W\|$ semakin kecil, maka margin yang diperoleh akan semakin besar. Margin yang besar membantu model menghasilkan batas kelas yang lebih stabil.

Pada data citra daun, pola fitur tidak selalu dapat dipisahkan secara linear. Beberapa daun dapat memiliki warna yang mirip, tetapi bentuk dan teksturnya berbeda. Sebaliknya, beberapa daun juga dapat memiliki bentuk yang mirip, tetapi memiliki warna atau tekstur yang berbeda. Oleh karena itu, penelitian ini menggunakan *kernel Radial Basis Function* (RBF) karena kernel tersebut dapat membantu SVM membaca pola data yang tidak linear. Rumus kernel RBF dapat dituliskan sebagai berikut:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.26)$$

Keterangan:

$K(x_i, x_j)$ = nilai kernel antara data x_i dan x_j

x_i = data ke- i

x_j = data ke- j

γ = parameter gamma pada kernel RBF

$\|x_i - x_j\|^2$ = kuadrat jarak antara dua data

Persamaan (2.26) menunjukkan bahwa kernel RBF menghitung kedekatan antara dua data berdasarkan jaraknya. Jika dua data memiliki jarak yang dekat, maka nilai kernel akan lebih besar. Sebaliknya, jika jaraknya jauh, maka nilai kernel akan lebih kecil. Pada klasifikasi citra daun, kernel RBF membantu model membentuk batas keputusan yang lebih fleksibel.

Karena penelitian ini menggunakan lebih dari dua kelas daun, maka SVM diterapkan dalam bentuk multiclass. Salah satu pendekatan yang dapat digunakan adalah one-versus-one. Pendekatan ini membentuk beberapa model biner berdasarkan pasangan kelas. Jumlah model biner pada pendekatan one-versus-one dapat dihitung sebagai berikut:

$$\text{Jumlah model} = \frac{k(k-1)}{2} \quad (2.27)$$

Keterangan:

k = jumlah kelas

Jumlah model = jumlah model biner yang dibentuk

Persamaan (2.27) menunjukkan bahwa jumlah model biner bergantung pada jumlah kelas yang digunakan. Karena penelitian ini menggunakan empat kelas daun, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih, maka jumlah model biner yang dibentuk adalah enam model. Penggunaan Multiclass SVM kernel RBF pada klasifikasi tanaman herbal juga sejalan dengan penelitian Amriana dkk. (2025) yang menunjukkan bahwa pengaturan parameter SVM dapat meningkatkan kinerja klasifikasi tanaman herbal.

2.8 Kombinasi Fitur Visual pada Klasifikasi Citra Daun

Klasifikasi citra daun membutuhkan fitur visual yang mampu mewakili karakter daun secara jelas. Pada penelitian ini, fitur yang digunakan terdiri atas warna, tekstur, dan bentuk. Ketiga fitur tersebut dipilih karena setiap jenis daun tidak hanya berbeda dari warna, tetapi juga dari pola permukaan dan bentuk morfologinya. Daun jambu biji, kunyit, pepaya, dan sirih memiliki ciri visual yang berbeda. Perbedaan tersebut dapat diolah menjadi nilai numerik agar dapat dipelajari oleh model klasifikasi.

Fitur warna digunakan untuk membaca perbedaan warna dominan pada daun. Ruang warna HSV membantu sistem membaca warna daun melalui komponen hue, saturation, dan value. HSV lebih sesuai untuk citra daun karena warna hijau daun dapat dipengaruhi oleh pencahayaan, bayangan, dan kondisi kamera. Ramli dkk. (2025) menggunakan fitur HSV dan GLCM untuk klasifikasi penyakit daun padi dengan metode SVM. Penelitian tersebut menunjukkan bahwa

fitur warna dan tekstur dapat digunakan sebagai dasar klasifikasi citra daun (Ramli dkk., 2025).

Fitur tekstur digunakan untuk membaca pola permukaan daun. Tekstur daun dapat terlihat dari tingkat kehalusan, kekasaran, dan sebaran intensitas piksel pada citra. *Gray Level Co-occurrence Matrix* atau GLCM banyak digunakan karena mampu membaca hubungan antar piksel pada jarak dan sudut tertentu. Johari dkk. (2025) juga menggunakan GLCM bersama fitur warna HSV dan Lab pada klasifikasi penyakit daun jagung. Hasil penelitian tersebut menunjukkan bahwa kombinasi fitur visual dapat meningkatkan kemampuan model dalam membaca perbedaan citra daun (Johari dkk., 2025).

Fitur bentuk digunakan untuk membaca geometri daun. Fitur ini penting karena beberapa daun memiliki bentuk yang sangat khas. Daun pepaya memiliki bentuk menjari, daun kunyit memanjang, daun sirih berbentuk menyerupai jantung, sedangkan daun jambu biji cenderung elips. Lubis dkk. (2024) menjelaskan bahwa fitur morfologi seperti area, perimeter, aspect ratio, circularity, dan Hu Moments dapat digunakan bersama GLCM untuk mengenali pola daun tanaman obat (Lubis dkk., 2024).

2.9 Pengenalan Cita Luar Kelas

Pada sistem klasifikasi biasa, setiap citra uji akan masuk ke salah satu kelas yang telah dilatih. Kondisi ini disebut klasifikasi tertutup. Masalah muncul ketika citra yang diuji ternyata berasal dari kelas yang tidak ada dalam data training. Jika sistem tetap memberi label pada citra tersebut, maka hasil prediksi dapat menyesatkan.

Masalah tersebut berkaitan dengan konsep open set recognition. Geng dkk. (2021) menjelaskan bahwa sistem pengenalan pada kondisi nyata tidak cukup hanya mengenali kelas yang sudah dipelajari. Sistem juga perlu mampu menghadapi sampel dari kelas yang belum pernah dilatih. Dalam konteks penelitian ini, sistem tidak hanya harus mengenali daun jambu biji, kunyit, pepaya, dan sirih. Sistem juga perlu menolak citra daun lain yang tidak termasuk empat kelas tersebut (Geng dkk., 2021).

Vaze dkk. (2021) menjelaskan bahwa open set recognition bertujuan mengetahui apakah suatu citra masih termasuk kelas yang dikenal atau berasal dari kelas yang belum dikenal. Pada kondisi open set, model tidak hanya memberi prediksi kelas, tetapi juga perlu memiliki indikator untuk menyatakan bahwa citra tidak sesuai dengan kelas data latih (Vaze dkk., 2021).


Pada penelitian ini, prinsip tersebut diterapkan melalui mekanisme penolakan citra luar kelas. Sistem memeriksa tiga hal, yaitu probabilitas prediksi SVM, jarak fitur citra uji terhadap centroid kelas, dan nilai kemiripan citra terhadap kelas terdekat. Citra hanya diterima jika memenuhi seluruh syarat. Jika salah satu syarat tidak terpenuhi, citra dinyatakan bukan dari data yang telah dilatih.

BAB III

METODOLOGI PENELITIAN

3.1 Desain Alur Penelitian

Desain alur penelitian menjelaskan tahapan kerja yang dilakukan dalam penelitian klasifikasi tanaman herbal berdasarkan citra daun yang disajikan pada gambar 3.1.



Gambar 3. 1 Desain alur penelitian

Berdasarkan gambar 3.1, alur penelitian dimulai dari pengumpulan data citra daun, pra pengolahan citra, ekstraksi fitur, pembagian data, pelatihan model, evaluasi model, uji manual citra, sampai diperoleh hasil klasifikasi. Penyusunan alur ini bertujuan agar setiap tahap penelitian berjalan runtut dan hasil penelitian dapat ditelusuri berdasarkan proses yang dilakukan.

3.1.1 Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data sekunder yang diperoleh dari dataset tanaman herbal pada platform Kaggle (<https://www.kaggle.com/datasets/anefiamutiaraatha/dataset-tanaman-herbal>).

Dataset tersebut digunakan karena sudah tersusun dalam folder kelas, sehingga sesuai dengan kebutuhan klasifikasi citra berbasis *supervised learning*. Penelitian ini menggunakan empat kelas daun herbal, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih. Setiap kelas berisi 100 citra, sehingga jumlah keseluruhan data yang digunakan adalah 400 citra.

Distribusi jumlah citra pada setiap kelas penelitian disajikan Tabel 3.1.


Tabel 3. 1 Distribusi Citra Daun Herbal Penelitian

No	Kelas Daun Herbal	Jumlah Citra	Contoh Gambar
1	Daun Jambu Biji	100	
2	Daun Kunyit	100	
3	Daun Pepaya	100	
4	Daun Sirih	100	
Total		400	

Berdasarkan Tabel 3.1, setiap kelas memiliki jumlah data yang sama. Komposisi data yang seimbang membantu proses pembagian data training dan testing agar setiap kelas tetap terwakili dengan baik.

3.1.2 Desain Sistem

Desain sistem pada penelitian ini menggambarkan proses klasifikasi citra daun herbal dari tahap masukan hingga menghasilkan keputusan akhir. Sistem tidak membaca citra hanya sebagai gambar, tetapi mengubah citra menjadi kumpulan nilai fitur yang mewakili warna, tekstur, dan bentuk daun. Nilai fitur tersebut kemudian digunakan oleh model Multiclass Support Vector Machine untuk menentukan kelas daun. Alur desain sistem ditunjukkan pada Gambar 3.2.



Gambar 3. 2 Desain Sistem

Berdasarkan Gambar 3.2, proses pada sistem dapat dijelaskan sebagai berikut.

a. Input citra daun herbal

Tahap pertama adalah memasukkan citra daun herbal ke dalam sistem. Citra yang digunakan dapat berasal dari dataset maupun dari hasil unggah manual. Secara sederhana, citra digital dapat dipahami sebagai kumpulan piksel. Setiap piksel memiliki nilai warna yang tersusun dari komponen merah, hijau, dan biru. Bentuk citra digital dapat dituliskan sebagai berikut.

$$I(x, y) = [R(x, y), G(x, y), B(x, y)] \quad (3.1)$$

Keterangan:

$I(x, y)$ = citra pada posisi piksel ke- x dan ke- y

$R(x, y)$ = nilai warna merah pada piksel ke- x dan ke- y

$G(x, y)$ = nilai warna hijau pada piksel ke- x dan ke- y

$B(x, y)$ = nilai warna biru pada piksel ke- x dan ke- y

Persamaan (3.1) menjelaskan bahwa satu citra digital tersusun dari banyak piksel. Nilai piksel inilah yang menjadi dasar proses pengolahan citra sebelum masuk ke tahap klasifikasi.

b. Pra pengolahan citra

Tahap pra pengolahan citra dilakukan untuk menyiapkan citra sebelum fitur diekstraksi. Pada penelitian ini, citra diubah ukurannya menjadi 224 x 224 piksel agar seluruh data memiliki ukuran yang sama. Setelah itu, citra dikonversi dari ruang warna BGR ke HSV. Ruang warna HSV digunakan karena lebih mudah memisahkan objek daun berdasarkan karakter warna hijau. Proses perubahan ukuran citra dapat dituliskan sebagai berikut.

$$I_r = \text{Resize}(I, 224, 224) \quad (3.2)$$

Keterangan:

I_r = citra hasil perubahan ukuran

I = citra masukan awal

Resize = proses mengubah ukuran citra

224,224 = ukuran citra yang digunakan dalam penelitian, yaitu 224 x 224 piksel

Persamaan (3.2) menjelaskan bahwa seluruh citra masukan diseragamkan menjadi ukuran yang sama. Penyeragaman ukuran ini penting agar proses ekstraksi fitur berjalan lebih stabil.

Setelah ukuran citra diseragamkan, sistem melakukan segmentasi daun menggunakan rentang warna HSV. Pada kode program, rentang warna hijau

ditentukan dari nilai *lower green* [20,20,20] sampai *upper green* [100,255,255].

Rumus segmentasi mask dapat dituliskan sebagai berikut.

$$M(x, y) = \begin{cases} 1, & \text{jika } 20 \leq H(x, y) \leq 100, 20 \leq S(x, y) \leq 255, 20 \leq V(x, y) \leq 255 \\ 0, & \text{selain kondisi tersebut} \end{cases} \quad (3.3)$$

Keterangan:

$M(x, y)$ = nilai mask pada piksel ke- x dan ke- y

$H(x, y)$ = nilai *Hue* pada piksel ke- x dan ke- y

$S(x, y)$ = nilai *Saturation* pada piksel ke- x dan ke- y

$V(x, y)$ = nilai *Value* pada piksel ke- x dan ke- y

1 = piksel termasuk area daun

0 = piksel termasuk latar belakang

Persamaan (3.3) menjelaskan bahwa piksel akan dianggap sebagai area daun apabila nilai HSV berada pada rentang yang telah ditentukan. Jika nilai piksel berada di luar rentang tersebut, piksel dianggap sebagai latar belakang.

c. Ekstraksi fitur citra daun

Tahap ekstraksi fitur bertujuan mengubah citra daun menjadi data numerik. Fitur yang digunakan dalam penelitian ini terdiri atas fitur warna HSV, fitur tekstur GLCM, dan fitur bentuk berbasis kontur serta Hu Moment. Ekstraksi fitur warna dilakukan dengan menghitung rata-rata dan standar deviasi komponen HSV pada area daun. Rumus rata-rata komponen HSV dapat dituliskan sebagai berikut.

$$\bar{H} = \frac{1}{N} \sum_{i=1}^N H_i \quad (3.4)$$

Keterangan:

$\bar{H}$ = rata-rata nilai *Hue* pada area daun

N = jumlah piksel daun yang terdeteksi pada mask

H_i = nilai *Hue* pada piksel daun ke- i

Persamaan (3.4) digunakan untuk memperoleh rata-rata warna daun. Cara yang sama juga digunakan untuk menghitung rata-rata *Saturation* dan *Value*.

Selain rata-rata, sistem juga menghitung standar deviasi untuk melihat sebaran nilai warna pada area daun. Rumus standar deviasi dapat dituliskan sebagai berikut.

$$\sigma_H = \sqrt{\frac{1}{N} \sum_{i=1}^N (H_i - \bar{H})^2} \quad (3.5)$$

Keterangan:

σ_H = standar deviasi nilai *Hue* pada area daun

N = jumlah piksel daun yang terdeteksi pada mask

H_i = nilai *Hue* pada piksel daun ke- i

$\bar{H}$ = rata-rata nilai *Hue* pada area daun

Persamaan (3.5) menjelaskan tingkat sebaran warna pada daun. Cara yang sama juga digunakan untuk menghitung standar deviasi *Saturation* dan *Value*.

Pada fitur tekstur, sistem menggunakan Gray Level Co-occurrence Matrix (GLCM). GLCM digunakan untuk membaca hubungan antar piksel pada citra grayscale. Sebelum menghitung fitur tekstur, matriks GLCM perlu dinormalisasi terlebih dahulu agar nilainya berubah menjadi peluang kemunculan pasangan piksel. Rumus normalisasi GLCM dapat dituliskan sebagai berikut.

$$P(i, j) = \frac{M(i, j)}{\sum_i \sum_j M(i, j)} \quad (3.6)$$

Keterangan:

$P(i, j)$ = peluang kemunculan pasangan piksel dengan intensitas i dan j

$M(i, j)$ = jumlah kemunculan pasangan piksel dengan intensitas i dan j

i = nilai intensitas piksel pertama

j = nilai intensitas piksel kedua

Persamaan (3.6) menjelaskan bahwa nilai GLCM dihitung dari jumlah kemunculan pasangan piksel tertentu, kemudian dibagi dengan seluruh jumlah pasangan piksel. Nilai hasil normalisasi digunakan untuk menghitung fitur tekstur seperti *contrast*, *correlation*, *energy*, *homogeneity*, *dissimilarity*, dan ASM.

Pada fitur bentuk, sistem menghitung beberapa ukuran dari kontur daun, seperti area, perimeter, *aspect ratio*, *extent*, *solidity*, *circularity*, *eccentricity*, dan Hu Moment. Salah satu fitur bentuk yang digunakan adalah *circularity*. Rumusnya dapat dituliskan sebagai berikut.

$$Circularity = \frac{4\pi A}{P^2} \quad (3.7)$$

Keterangan:

A = area atau luas objek daun hasil segmentasi

P = perimeter atau keliling kontur daun

π = konstanta phi

Circularity = nilai tingkat kebulatan objek daun

Persamaan (3.7) menjelaskan bahwa nilai *circularity* digunakan untuk melihat tingkat kebulatan objek daun. Nilai yang semakin mendekati 1 menunjukkan bahwa bentuk objek semakin menyerupai lingkaran.

d. Klasifikasi dengan SVM

Tahap klasifikasi dilakukan menggunakan Multiclass Support Vector Machine dengan kernel RBF. Kernel RBF dipilih karena pola fitur citra daun tidak selalu dapat dipisahkan secara linear. Rumus kernel RBF dapat dituliskan sebagai berikut.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3.8)$$

Keterangan:

$K(x_i, x_j)$ = nilai kernel antara data fitur ke- i dan data fitur ke- j

x_i = vektor fitur data ke- i

x_j = vektor fitur data ke- j

γ = parameter gamma yang mengatur jangkauan pengaruh data

$\|x_i - x_j\|^2$ = kuadrat jarak antara dua vektor fitur

Persamaan (3.8) menjelaskan bahwa kernel RBF menghitung kedekatan dua data berdasarkan jaraknya. Jika dua data memiliki fitur yang dekat, nilai kernel menjadi lebih besar.

Setelah model menghasilkan probabilitas setiap kelas, sistem memilih probabilitas tertinggi sebagai prediksi awal. Rumusnya dapat dituliskan sebagai berikut.

$$p_{max} = \max(P_c) \quad (3.9)$$

Keterangan:

p_{max} = probabilitas tertinggi dari hasil prediksi SVM

P_c = probabilitas citra uji terhadap kelas c

c = kelas daun yang terdiri atas jambu biji, kunyit, pepaya, dan sirih

Persamaan (3.9) menjelaskan bahwa prediksi awal sistem diambil dari

kelas dengan probabilitas tertinggi.

e. Hasil klasifikasi citra

Tahap akhir adalah menampilkan hasil klasifikasi citra. Sistem tidak hanya menampilkan kelas prediksi, tetapi juga memeriksa apakah citra tersebut layak diterima sebagai salah satu kelas data latih. Pemeriksaan dilakukan menggunakan jarak terhadap centroid kelas dan nilai kemiripan. Rumus jarak Euclidean terhadap centroid kelas dapat dituliskan sebagai berikut.

$$d_c = \sqrt{\sum_{k=1}^n (z_k - \mu_{ck})^2} \quad (3.10)$$

Keterangan:

d_c = jarak citra uji terhadap centroid kelas c

z_k = nilai fitur ke- k pada citra uji setelah normalisasi

μ_{ck} = nilai centroid kelas c pada fitur ke- k

n = jumlah fitur yang digunakan

k = urutan fitur

Persamaan (3.10) menjelaskan bahwa citra uji akan dibandingkan dengan pusat fitur pada setiap kelas. Jarak yang lebih kecil menunjukkan bahwa citra uji lebih dekat dengan kelas tersebut.

Nilai jarak kemudian diubah menjadi persentase kemiripan. Rumusnya dapat dituliskan sebagai berikut.

$$S_c = \frac{100}{1 + \frac{d_c}{T_c}} \quad (3.11)$$

Keterangan:

S_c = persentase kemiripan citra uji terhadap kelas c

d_c = jarak citra uji terhadap centroid kelas c

T_c = threshold jarak pada kelas c

Persamaan (3.11) menjelaskan bahwa nilai kemiripan akan semakin besar apabila jarak citra uji semakin dekat dengan centroid kelas. Citra hanya diterima apabila memenuhi syarat probabilitas, kemiripan, dan konsistensi kelas. Aturan keputusan akhir dapat dituliskan sebagai berikut.

$$Keputusan = \begin{cases} Diterima, & \text{jika } p_{max} \geq 0,55, S_{pred} \geq 50, y_{pred} = y_{nearest} \\ Ditolak, & \text{selain kondisi tersebut} \end{cases} \quad (3.12)$$

Keterangan:

p_{max} = probabilitas tertinggi dari SVM

S_{pred} = nilai kemiripan pada kelas hasil prediksi SVM

y_{pred} = kelas hasil prediksi SVM

$y_{nearest}$ = kelas terdekat berdasarkan nilai kemiripan tertinggi

Diterima = citra masuk ke salah satu kelas data latih

Ditolak = citra dinyatakan bukan dari data yang telah dilatih

Persamaan (3.12) menjelaskan bahwa sistem tidak langsung menerima setiap citra sebagai salah satu kelas. Citra hanya diterima apabila seluruh syarat terpenuhi. Pendekatan ini sesuai dengan prinsip pengenalan citra luar kelas atau *open set recognition*, yaitu sistem perlu mampu menolak data yang tidak termasuk kelas yang telah dipelajari.

3.1.3 Perhitungan Manual

Perhitungan manual pada penelitian ini difokuskan pada cara kerja Support Vector Machine (SVM) dalam membaca nilai fitur dan menentukan kelas citra daun. Contoh citra yang digunakan adalah Daun jambu biji.JPG. Citra ini dipilih untuk menunjukkan alur perhitungan mulai dari fitur citra, normalisasi fitur,

perhitungan kernel RBF, penentuan probabilitas kelas, hingga keputusan akhir sistem.

Nilai fitur citra uji Daun jambu biji.JPG disajikan pada Tabel 3.2.

Tabel 3. 2 Nilai fitur citra uji daun jambu biji

No	Nama Fitur	Nilai
1	color_mean_h	38,897565
2	color_mean_s	142,148623
3	color_mean_v	118,322315
4	color_std_h	2,775852
5	color_std_s	37,077706
6	color_std_v	19,479531
7	texture_contrast	0,326383
8	texture_correlation	0,585551
9	texture_energy	0,554060
10	texture_homogeneity	0,858368
11	texture_dissimilarity	0,290316
12	texture_asm	0,307108
13	shape_area	24776,000000
14	shape_perimeter	618,073156
15	shape_aspect_ratio	1,489655
16	shape_extent	0,791060
17	shape_solidity	0,986070
18	shape_circularity	0,815007
19	shape_eccentricity	0,733483
20	shape_hu_1	0,761617
21	shape_hu_2	2,355519
22	shape_hu_3	4,292304
23	shape_hu_4	5,749751
24	shape_hu_5	-11,027074
25	shape_hu_6	-7,141991
26	shape_hu_7	10,803355

Berdasarkan Tabel 3.2, citra uji memiliki 26 fitur numerik. Fitur tersebut terdiri atas 6 fitur warna, 6 fitur tekstur, dan 14 fitur bentuk. Nilai fitur ini tidak langsung dibandingkan dalam bentuk asli karena setiap fitur memiliki rentang nilai yang berbeda. Oleh karena itu, sebelum masuk ke model SVM, seluruh fitur terlebih dahulu dinormalisasi menggunakan StandardScaler.

Tahap pertama dalam perhitungan SVM adalah melakukan normalisasi fitur. Normalisasi dilakukan agar fitur yang memiliki nilai besar, seperti area dan perimeter, tidak mendominasi fitur lain yang nilainya lebih kecil. Rumus normalisasi fitur dapat dituliskan sebagai berikut.

$$z_j = (x_j - \mu_j) / \sigma_j \quad (3.13)$$

Keterangan:

z_j = nilai fitur ke-j setelah normalisasi

x_j = nilai fitur ke-j sebelum normalisasi

μ_j = rata-rata fitur ke-j pada data training

σ_j = standar deviasi fitur ke-j pada data training

j = urutan fitur yang digunakan

Melalui Persamaan (3.13), setiap nilai fitur citra uji diubah ke dalam skala yang sama dengan data training. Hasil normalisasi tersebut menjadi vektor fitur baru yang dibaca oleh SVM.

Tahap kedua adalah menghitung fungsi keputusan SVM. Pada penelitian ini digunakan kernel Radial Basis Function (RBF), sehingga SVM dapat memisahkan pola fitur yang tidak sepenuhnya linear. Fungsi keputusan SVM untuk dua kelas dapat dituliskan sebagai berikut.

$$f_{a\beta}(x) = \sum \alpha_i y_i K(x_i, x) + b_{a\beta} \quad (3.14)$$

Keterangan:

$f_{a\beta}(x)$ = nilai fungsi keputusan antara kelas a dan kelas b

α_i = koefisien support vector

y_i = label kelas pada data support vector

$K(x_i, x)$ = nilai kernel antara data support vector dan citra uji

$b_{a\beta}$ = bias pada model SVM

Nilai kernel RBF yang digunakan pada fungsi keputusan dapat dituliskan sebagai berikut.

$$K(x_i, x) = \exp(-\gamma ||x_i - x||^2) \quad (3.15)$$

Keterangan:

$K(x_i, x)$ = nilai kedekatan antara data support vector dan citra uji

γ = parameter gamma pada kernel RBF
 x_i = vektor fitur data support vector
 x = vektor fitur citra uji
 $\|x_i - x\|^2$ = kuadrat jarak antara dua vektor fitur

Persamaan (3.14) dan Persamaan (3.15) menunjukkan bahwa SVM tidak menilai citra hanya dari satu fitur, tetapi dari kombinasi seluruh fitur yang telah dinormalisasi. Semakin sesuai pola fitur citra uji dengan pola data training suatu kelas, semakin kuat kecenderungan SVM memilih kelas tersebut.

Tahap ketiga adalah menentukan probabilitas kelas. Model SVM menghasilkan nilai probabilitas untuk setiap kelas daun. Kelas dengan probabilitas paling besar digunakan sebagai hasil prediksi SVM. Rumus probabilitas tertinggi

$$P_{\max} = \max P(y = k | x) \quad (3.16)$$

Keterangan:

$P_{\max}$ = probabilitas tertinggi dari hasil SVM
 $P(y = k | x)$ = probabilitas citra uji x termasuk ke kelas k
 k = kelas daun, yaitu jambu biji, kunyit, pepaya, dan sirih
 Kelas prediksi SVM ditentukan menggunakan probabilitas tertinggi tersebut. Rumusnya dapat dituliskan sebagai berikut.

$$\hat{y}_{\text{SVM}} = \arg \max_k P(y = k | x) \quad (3.17)$$

Keterangan:

$\hat{y}_{\text{SVM}}$ = kelas hasil prediksi SVM
 $\arg \max$ = proses memilih kelas dengan nilai probabilitas terbesar
 $P(y = k | x)$ = probabilitas citra uji terhadap kelas k

Berdasarkan hasil perhitungan sistem, citra Daun jambu biji.JPG memperoleh probabilitas tertinggi pada kelas Daun Jambu Biji. Perhitungannya dituliskan sebagai berikut. Perhitungan ini tidak diberi nomor persamaan karena hanya merupakan substitusi nilai dari hasil sistem.

$$P(y = \text{Daun Jambu Biji} | x) = 0,9965$$

$$P_{\max} = 0,9965 \times 100\%$$

$$P_{\max} = 99,65\%$$

$$\hat{y}_{SVM} = \text{Daun Jambu Biji}$$

Hasil tersebut menunjukkan bahwa model SVM paling kuat mengenali citra uji sebagai Daun Jambu Biji. Nilai probabilitas 99,65% juga lebih tinggi dari ambang probabilitas yang digunakan, yaitu 55%.

Setelah prediksi SVM diperoleh, sistem masih melakukan pemeriksaan tambahan menggunakan jarak fitur terhadap centroid kelas. Pemeriksaan ini digunakan untuk membantu menolak citra yang tidak termasuk ke dalam data latih. Perhitungan jarak dan kemiripan menggunakan rumus yang telah dijelaskan pada Persamaan (3.10) dan Persamaan (3.11). Contoh perhitungan kemiripan terhadap kelas Daun Jambu Biji adalah sebagai berikut.

$$\text{Kemiripan Daun Jambu Biji} =$$

$$100 / (1 + (3,0296 / 5,0386)) = 100 / (1 + 0,6013) = 62,45\%$$

Hasil perhitungan jarak, threshold, dan kemiripan citra uji terhadap setiap kelas disajikan pada Tabel 3.3.

Tabel 3. 3 Perhitungan jarak, threshold, dan kemiripan citra uji

Kelas	Jarak (d_k)	Threshold (T_k)	Kemiripan (S_k)
Daun Jambu Biji	3,0296	5,0386	62,45%
Daun Kunyit	5,7519	5,2523	47,73%
Daun Pepaya	6,6995	4,8573	42,03%
Daun Sirih	4,6145	4,4692	49,20%

Berdasarkan Tabel 3.3, kemiripan tertinggi berada pada kelas Daun Jambu Biji sebesar 62,45%. Kelas terdekat berdasarkan centroid juga sama dengan prediksi SVM, yaitu Daun Jambu Biji. Artinya, hasil SVM dan hasil pemeriksaan kemiripan menunjukkan kelas yang konsisten.

Tahap terakhir adalah menentukan keputusan akhir. Sistem menerima citra sebagai kelas target apabila tiga syarat terpenuhi, yaitu probabilitas SVM mencapai ambang minimum, kemiripan terhadap kelas prediksi mencapai ambang minimum, dan kelas hasil SVM sama dengan kelas terdekat berdasarkan centroid. Hasil pemeriksaan keputusan akhir disajikan pada Tabel 3.4.

Tabel 3. 4 Keputusan akhir pada citra uji

Syarat Keputusan	Nilai Citra Uji	Ambang	Keputusan
Probabilitas tertinggi SVM	99,65%	$\geq 55\%$	Terpenuhi
Kemiripan prediksi	62,45%	$\geq 50\%$	Terpenuhi
Konsistensi kelas	Prediksi SVM = kelas terdekat	Harus sama	Terpenuhi
Hasil akhir	Daun Jambu Biji	-	Terdeteksi

Berdasarkan Tabel 3.4, citra Daun jambu biji.JPG diterima oleh sistem dan dinyatakan terdeteksi sebagai Daun Jambu Biji. Keputusan ini diperoleh karena prediksi SVM memiliki probabilitas tinggi, nilai kemiripan memenuhi ambang minimum, dan kelas prediksi SVM sesuai dengan kelas terdekat berdasarkan centroid.

3.1.4 Skenario Pengujian

Skenario pengujian disusun untuk mengetahui kemampuan sistem dalam dua kondisi, yaitu mengenali citra daun yang termasuk kelas target dan menolak citra daun yang tidak termasuk kelas target. Pengujian ini diperlukan karena pada penggunaan nyata, pengguna dapat memasukkan citra daun yang belum pernah dipelajari oleh model. Oleh karena itu, sistem tidak cukup hanya menghasilkan prediksi SVM, tetapi juga perlu memeriksa probabilitas, kemiripan fitur, dan konsistensi kelas.

Pada penelitian ini, pengujian manual dilakukan setelah model SVM selesai dilatih. Setiap citra uji akan melalui tahapan yang sama, yaitu preprocessing, segmentasi, ekstraksi fitur, normalisasi fitur, prediksi SVM, perhitungan kemiripan terhadap centroid, dan penentuan keputusan akhir. Ambang yang digunakan pada pengujian manual adalah probabilitas minimal 55% dan kemiripan minimal 50%.

Tabel 3. 5 Variasi citra pada pengujian manual

No	Variasi Citra	Keterangan
1	Citra target	Citra berasal dari kelas yang digunakan pada proses pelatihan model, yaitu daun jambu biji, daun kunyit, daun pepaya, dan daun sirih.
2	Citra luar kelas dengan bentuk mirip	Citra tidak termasuk data latih, tetapi memiliki bentuk daun yang menyerupai salah satu kelas target.
3	Citra luar kelas dengan warna atau tekstur mirip	Citra tidak termasuk data latih, tetapi memiliki warna, pola permukaan, atau tekstur yang mendekati salah satu kelas target.

Berdasarkan Tabel 3.5, pengujian manual tidak hanya menggunakan citra target, tetapi juga citra luar kelas. Cara ini dilakukan agar sistem dapat diuji secara lebih nyata, yaitu apakah sistem mampu menerima citra yang benar dan menolak citra yang tidak sesuai dengan kelas data latih.

Tabel 3. 6 Skenario pengujian citra daun

No	Skenario	Kelas Target	Citra yang Diuji	Karakteristik Kemiripan
1	Mirip Daun Jambu Biji	Jambu Biji	Jambu biji, ketapang, nangka, alpukat, salam, sirsak	Bentuk lonjong sampai oval, tulang daun menyirip, dan warna hijau relatif serupa.
2	Mirip Daun Kunyit	Kunyit	Kunyit, lengkuas, bangle, jahe, kapulaga, lempuyang	Kelompok rimpang dengan daun memanjang, tulang daun sejajar, dan warna yang hampir sama.
3	Mirip Daun Pepaya	Pepaya	Pepaya, kapuk randu, mentimun, daun gedi, ganja, singkong	Pola daun menjari, bercabang, atau berlekuk menyerupai struktur daun pepaya.
4	Mirip Daun Sirih	Sirih	Sirih, waru, begonia, ubi jalar, talas, binahong	Bentuk daun menyerupai jantung, ujung meruncing, dan warna hijau yang relatif mirip.

Berdasarkan Tabel 3.6, setiap skenario terdiri atas satu citra target dan lima citra pembanding dari luar kelas target. Sistem diharapkan mampu mendeteksi citra target sesuai kelasnya, sedangkan citra pembanding yang tidak termasuk data latih diharapkan ditolak apabila tidak memenuhi ambang probabilitas, kemiripan, atau konsistensi kelas. Dengan skenario ini, pengujian tidak hanya melihat akurasi pada kelas target, tetapi juga melihat kemampuan sistem dalam menghadapi citra luar kelas.

3.2 Implementasi

Implementasi sistem dilakukan menggunakan bahasa pemrograman Python pada Google Colab. Tahap implementasi mengikuti desain sistem yang telah dijelaskan sebelumnya, yaitu persiapan dataset, preprocessing dan segmentasi citra, ekstraksi fitur, pembagian data, pelatihan model Multiclass SVM, evaluasi model, dan uji manual citra daun. Potongan kode pada bagian ini diberi caption sebagai gambar agar urutan kode dan keterangannya lebih jelas.

3.2.1 Persiapan Dataset

Tahap persiapan dataset digunakan untuk menentukan ukuran citra, rasio pembagian data, nilai *random state*, dan daftar kelas penelitian. Label kelas disederhanakan agar mudah diproses oleh sistem

```
IMAGE_SIZE = (224, 224)
TEST_SIZE = 0.20
RANDOM_STATE = 42
CLASS_FOLDER_MAP = {
    "Daun Jambu Biji": "jambu_biji",
    "Daun Kunyit": "kunyit",
    "Daun Pepaya": "pepaya",
    "Daun Sirih": "sirih"
}
TARGET_CLASSES = ["jambu_biji", "kunyit", "pepaya", "sirih"]
```

Gambar 3. 3 Kode program persiapan dataset

Gambar 3.3 menunjukkan kode untuk menyiapkan parameter awal penelitian. Variabel `IMAGE_SIZE` menentukan ukuran citra, `TEST_SIZE` menentukan rasio data testing, `RANDOM_STATE` menjaga hasil pembagian data agar konsisten, sedangkan `CLASS_FOLDER_MAP` dan `TARGET_CLASSES` digunakan untuk membaca kelas citra daun, dengan output yang dihasilkan sebagai berikut.

```
Parameter penelitian berhasil disiapkan.
Kelas penelitian: ['jambu_biji', 'kunyit', 'pepaya', 'sirih']
```

Gambar 3. 4 Output persiapan dataset

Gambar 3.4 menunjukkan bahwa parameter penelitian berhasil disiapkan dan kelas penelitian telah terdaftar di dalam sistem.


3.2.2 Preprocessing dan Segmentasi Citra

Tahap preprocessing bertujuan menyeragamkan ukuran citra menjadi 224 x 224 piksel. Setelah itu, citra diubah dari BGR ke HSV untuk memudahkan proses segmentasi warna daun. Segmentasi dilakukan dengan menentukan rentang warna hijau, kemudian hasil mask diperbaiki menggunakan operasi morfologi open dan close.

```
def segment_leaf(image_bgr):
    image_bgr = cv2.resize(image_bgr, IMAGE_SIZE)
    hsv = cv2.cvtColor(image_bgr, cv2.COLOR_BGR2HSV)
    lower_green = np.array([20, 20, 20])
    upper_green = np.array([100, 255, 255])
    mask = cv2.inRange(hsv, lower_green, upper_green)
    kernel = np.ones((5, 5), np.uint8)
    mask = cv2.morphologyEx(mask, cv2.MORPH_OPEN, kernel)
    mask = cv2.morphologyEx(mask, cv2.MORPH_CLOSE, kernel)
    contours, _ = cv2.findContours(
        mask,
        cv2.RETR_EXTERNAL,
        cv2.CHAIN_APPROX_SIMPLE
    )
    largest_contour = max(contours, key=cv2.contourArea)
    return image_bgr, mask, largest_contour
```

Gambar 3. 5 Kode program preprocessing dan segmentasi citra

Gambar 3.5 menunjukkan proses resize, konversi warna ke HSV, pembuatan mask berdasarkan rentang warna hijau, serta pencarian kontur terbesar. Kontur terbesar digunakan karena objek utama yang dianalisis adalah daun.



Gambar 3. 6 Output preprocessing dan segmentasi citra

Gambar 3.6 menampilkan citra asli, hasil resize, mask segmentasi, dan citra hasil segmentasi. Output tersebut menunjukkan bahwa objek daun dapat dipisahkan dari latar belakang sebelum masuk ke tahap ekstraksi fitur.

3.2.3 Ekstraksi Fitur Citra

Ekstraksi fitur dilakukan untuk mengubah citra daun menjadi data numerik. Fitur yang digunakan terdiri atas fitur warna HSV, fitur tekstur GLCM, dan fitur bentuk berbasis kontur serta Hu Moment. Penggabungan beberapa fitur visual membantu sistem membaca karakter daun secara lebih lengkap.

```
COLOR_FEATURES = [
    "color_mean_h", "color_mean_s", "color_mean_v",
    "color_std_h", "color_std_s", "color_std_v"
]
TEXTURE_FEATURES = [
    "texture_contrast", "texture_correlation", "texture_energy",
    "texture_homogeneity", "texture_dissimilarity", "texture_asm"
]
SHAPE_FEATURES = [
    "shape_area", "shape_perimeter", "shape_aspect_ratio",
    "shape_extent", "shape_solidity", "shape_circularity",
    "shape_eccentricity", "shape_hu_1", "shape_hu_2",
    "shape_hu_3", "shape_hu_4", "shape_hu_5",
    "shape_hu_6", "shape_hu_7"
```

```

]
FEATURE_NAMES = COLOR_FEATURES + TEXTURE_FEATURES + SHAPE_FEATURES

```

Gambar 3. 7 Kode program ekstraksi fitur citra

Gambar 3.7 menunjukkan daftar fitur yang digunakan dalam penelitian. Fitur warna berjumlah 6 fitur, fitur tekstur berjumlah 6 fitur, dan fitur bentuk berjumlah 14 fitur. Seluruh fitur digabungkan menjadi FEATURE_NAMES.

```

Jumlah fitur warna: 6
Jumlah fitur tekstur: 6
Jumlah fitur bentuk: 14
Total fitur: 26

```

Gambar 3. 8 Output ekstraksi fitur citra

Gambar 3.8 menunjukkan total fitur yang digunakan sebanyak 26 fitur. Nilai fitur tersebut menjadi input utama bagi model Multiclass SVM.

3.2.4 Pembagian Data Training dan Testing

Setelah semua citra berhasil diekstraksi menjadi fitur numerik, data dibagi menjadi data training dan data testing. Data training digunakan untuk melatih model, sedangkan data testing digunakan untuk menguji kemampuan model terhadap data yang belum pernah dilihat saat pelatihan.

```

X = df_features[FEATURE_NAMES]
y = df_features["label"]
X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42,
    stratify=y
)

```

Gambar 3. 9 Kode program pembagian data training dan testing

Gambar 3.9 menunjukkan proses pembagian data menggunakan train_test_split. Parameter stratify=y digunakan agar proporsi setiap kelas tetap seimbang pada data training dan data testing.

```

Jumlah data training: 320
Jumlah data testing: 80

Distribusi data training:
label
kunyit      80
pepaya      80
jambu_biji  80
sirih       80
Name: count, dtype: int64

Distribusi data testing:
label
pepaya      20
kunyit      20
jambu_biji  20
sirih       20
Name: count, dtype: int64

```

Gambar 3. 10 Output pembagian data training dan testing

Gambar 3.10 menunjukkan jumlah data training sebanyak 320 citra dan data testing sebanyak 80 citra. Setiap kelas memiliki 80 citra training dan 20 citra testing.

3.2.5 Pelatihan Model Multiclass SVM

Pelatihan model dilakukan menggunakan Multiclass Support Vector Machine dengan kernel RBF. Sebelum dilatih, fitur dinormalisasi menggunakan StandardScaler agar seluruh fitur berada pada skala yang lebih seimbang. Pencarian parameter terbaik dilakukan menggunakan GridSearchCV pada parameter C dan gamma.

```

svm_pipeline = Pipeline([
    ("scaler", StandardScaler()),
    ("svm", SVC(
        kernel="rbf",
        probability=True,
        class_weight="balanced",
        random_state=42
    ))
])
param_grid = {
    "svm__C": [0.1, 1, 10, 100],
    "svm__gamma": [0.001, 0.01, 0.1, 1]
}
grid_search = GridSearchCV(
    estimator=svm_pipeline,
    param_grid=param_grid,

```

```

        cv=5,
        scoring="accuracy"
    )
    grid_search.fit(X_train, y_train)
    best_model = grid_search.best_estimator_

```

Gambar 3. 11 Kode program pelatihan model Multiclass SVM

Gambar 3.11 menunjukkan pipeline pelatihan yang menggabungkan StandardScaler dan SVC. Parameter probability=True digunakan agar model menghasilkan probabilitas prediksi. GridSearchCV digunakan untuk mencari kombinasi C dan gamma yang menghasilkan akurasi validasi terbaik.

```

Training SVM selesai.

Parameter terbaik:
{'svm__C': 10, 'svm__gamma': 0.1}

Akurasi validasi terbaik:
0.9875

```

Gambar 3. 12 Output pelatihan model Multiclass SVM

Gambar 3.12 menunjukkan bahwa proses training selesai dengan parameter terbaik C = 10 dan gamma = 0,1. Nilai akurasi validasi terbaik adalah 0,9875 atau 98,75%.

3.2.6 Implementasi Evaluasi Model

Evaluasi model dilakukan menggunakan data testing. Evaluasi bertujuan mengetahui kemampuan model dalam mengklasifikasikan citra baru yang tidak digunakan pada proses training. Ukuran evaluasi yang digunakan adalah akurasi, classification report, dan confusion matrix.


```

y_pred = best_model.predict(X_test)
accuracy = accuracy_score(y_test, y_pred)
report = classification_report(
    y_test,
    y_pred,
    zero_division=0
)
cm = confusion_matrix(
    y_test,
    y_pred,
    labels=best_model.classes_
)

```

Gambar 3. 13 Kode program evaluasi model

Gambar 3.13 menunjukkan kode untuk menghitung akurasi, classification report, dan confusion matrix. Akurasi digunakan untuk mengukur persentase prediksi benar, classification report digunakan untuk melihat precision, recall, dan f1-score, sedangkan confusion matrix digunakan untuk melihat jumlah prediksi benar dan salah pada setiap kelas.

Akurasi data testing:				
0.9625				
Classification Report:				
	precision	recall	f1-score	support
jambu_biji	0.95	0.95	0.95	20
kunyit	0.95	1.00	0.98	20
pepaya	1.00	0.95	0.97	20
sirih	0.95	0.95	0.95	20
accuracy			0.96	80
macro avg	0.96	0.96	0.96	80
weighted avg	0.96	0.96	0.96	80

Gambar 3. 14 Output evaluasi model

Gambar 3.14 menunjukkan hasil evaluasi model pada data testing. Nilai akurasi testing sebesar 0,9625 atau 96,25%.

3.2.7 Uji Manual Citra Daun

Uji manual citra daun dilakukan untuk melihat kemampuan sistem ketika pengguna mengunggah citra secara langsung. Citra yang diunggah akan melalui alur yang sama dengan data training, yaitu preprocessing, segmentasi, ekstraksi fitur, klasifikasi SVM, dan pemeriksaan penolakan citra luar kelas.

```

PROBABILITY_THRESHOLD = 0.55
MIN_SIMILARITY_THRESHOLD = 50.00
probabilities = best_model.predict_proba(X_new[FEATURE_NAMES])[0]
max_index = np.argmax(probabilities)
predicted_class = best_model.classes_[max_index]
max_probability = probabilities[max_index]
similarity_result = calculate_similarity_percent(
    model=best_model,
    new_feature_df=X_new,
    rejection_reference=REJECTION_REFERENCE,
    feature_names=FEATURE_NAMES
)
closest_class = similarity_result["kelas_terdekat"]
similarity_percent = similarity_result["kemiripan_persen"]
predicted_similarity = similarity_percent[predicted_class]
if (
    max_probability >= PROBABILITY_THRESHOLD
    and predicted_similarity >= MIN_SIMILARITY_THRESHOLD
    and predicted_class == closest_class
):
    final_output = predicted_class
    status = "terdeteksi"
else:
    final_output = "bukan_dari_data_yang_telah_dilatih"
    status = "ditolak"

```

Gambar 3. 15 Kode program uji manual citra daun

Gambar 3.15 menunjukkan kode keputusan akhir pada uji manual. Citra diterima apabila probabilitas tertinggi minimal 55%, kemiripan prediksi minimal 50%, dan kelas prediksi SVM sama dengan kelas terdekat berdasarkan fitur. Jika salah satu syarat tidak terpenuhi, citra ditolak sebagai bukan dari data yang telah dilatih.

```

Nama file: daun jambu biji.JPG
Skenario pengujian: Skenario 1 - Mirip Daun Jambu Biji
Target skenario: Daun Jambu Biji

HASIL AKHIR:
Terdeteksi sebagai Daun Jambu Biji dengan kemiripan 62.37%

Prediksi kelas oleh SVM:
Daun Jambu Biji

Probabilitas tertinggi SVM:
99.66%

Kelas terdekat berdasarkan fitur:
Daun Jambu Biji

Kemiripan terhadap setiap kelas:
- Daun Jambu Biji: 62.37%
- Daun Kunyit: 48.15%
- Daun Pepaya: 41.23%
- Daun Sirih: 49.98%

Probabilitas semua kelas dari SVM:
- Daun Jambu Biji: 99.66%
- Daun Kunyit: 0.06%
- Daun Pepaya: 0.08%
- Daun Sirih: 0.20%

Jarak fitur terhadap setiap kelas:
- Daun Jambu Biji: 3.0296
- Daun Kunyit: 5.6488
- Daun Pepaya: 6.7017
- Daun Sirih: 4.5348

```

Gambar 3. 16 Output uji manual citra daun

Gambar 3.16 menunjukkan output uji manual berupa nama file, skenario pengujian, hasil akhir, prediksi SVM, probabilitas tertinggi, kelas terdekat, nilai kemiripan, dan jarak fitur terhadap setiap kelas.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil

Bagian hasil menyajikan luaran utama yang diperoleh dari implementasi sistem klasifikasi daun herbal. Hasil penelitian memuat parameter terbaik, akurasi validasi, akurasi data testing, classification report, serta hasil pengujian manual terhadap citra target dan citra luar kelas.

4.1.1 Pelatihan dan Evaluasi Model SVM

Ringkasan hasil pelatihan model SVM disajikan pada Tabel 4.1.

Tabel 4. 1 Hasil pelatihan model SVM

No	Komponen Evaluasi	Hasil
1	Metode klasifikasi	Multiclass Support Vector Machine
2	Kernel	Radial Basis Function
3	Pembagian data	80% training dan 20% testing
4	Normalisasi fitur	StandardScaler
5	Optimasi parameter	GridSearchCV
6	Parameter terbaik	$C = 10$ dan $\gamma = 0,1$
7	Akurasi validasi terbaik	0,9875 atau 98,75%
8	Akurasi data testing	0,9625 atau 96,25%

Berdasarkan Tabel 4.1, kombinasi parameter terbaik adalah $C = 10$ dan $\gamma = 0,1$. Nilai akurasi validasi sebesar 98,75% menunjukkan bahwa model mampu belajar dengan baik pada data training. Nilai akurasi testing sebesar 96,25% menunjukkan bahwa model tetap mampu mengenali data baru yang tidak digunakan dalam proses pelatihan.

Akurasi data testing: 0.9625				
Classification Report:				
	precision	recall	f1-score	support
jambu_biji	0.95	0.95	0.95	20
kunyit	0.95	1.00	0.98	20
pepaya	1.00	0.95	0.97	20
sirih	0.95	0.95	0.95	20
accuracy			0.96	80
macro avg	0.96	0.96	0.96	80
weighted avg	0.96	0.96	0.96	80

Gambar 4. 1 Classification report data testing

Berdasarkan Gambar 4.1, setiap kelas memiliki jumlah data testing yang sama, yaitu 20 citra. Nilai precision, recall, dan f1-score berada pada rentang 0,95 sampai 1,00. Hasil ini menunjukkan bahwa model tidak hanya baik pada satu kelas, tetapi relatif seimbang dalam mengenali daun jambu biji, kunyit, pepaya, dan sirih.

4.1.2 Pengujian Manual Berdasarkan Skenario

Pengujian manual dilakukan pada 24 citra yang terdiri atas 4 citra target dan 20 citra luar kelas. Ringkasan hasil pengujian manual berdasarkan skenario disajikan pada Tabel 4.2.

Tabel 4. 2 Ringkasan hasil pengujian manual berdasarkan skenario

Skenario	Target	Jumlah Citra	Target Terdeteksi	Luar Kelas Ditolak	Luar Kelas Terdeteksi
Mirip Daun Jambu Biji	Daun Jambu Biji	6	1	5	0
Mirip Daun Kunyit	Daun Kunyit	6	1	5	0
Mirip Daun Pepaya	Daun Pepaya	6	1	4	1
Mirip Daun Sirih	Daun Sirih	6	1	3	2

Berdasarkan Tabel 4.4, sistem Berdasarkan Tabel 4.2, sistem berhasil mendeteksi seluruh citra target pada empat skenario. Sistem juga berhasil menolak 17 dari 20 citra luar kelas. Hasil ini menunjukkan bahwa mekanisme penolakan membantu sistem membedakan citra yang termasuk data latih dan citra yang tidak termasuk data latih.

Tabel 4. 3 Hasil Deteksi Citra Target

Citra Uji	Hasil Sistem	Probabilitas Tertinggi	Kemiripan Prediksi	Status
Daun jambu biji.JPG	Daun Jambu Biji	99,65%	62,45%	terdeteksi
Kunyit.JPG	Daun Kunyit	99,64%	56,21%	terdeteksi
Pepaya.JPG	Daun Pepaya	99,75%	61,18%	terdeteksi
Sirih.jpg	Daun Sirih	94,81%	56,68%	terdeteksi

Berdasarkan Tabel 4.3, seluruh citra target berhasil dikenali sesuai kelasnya.

Daun jambu biji, kunyit, pepaya, dan sirih memperoleh status terdeteksi karena nilai probabilitas dan kemiripannya melewati ambang yang telah ditentukan.

Tabel 4. 4 Ringkasan 24 Citra Uji Manual

No	Nama File	Jenis Data	Status	Prediksi SVM	Probabilitas	Kemiripan	Keterangan
1	Daun jambu biji.JPG	Target	terdeteksi	Daun Jambu Biji	99,65%	62,45%	Sesuai
2	Ketapang.jpg	Luar kelas	ditolak	Daun Kunyit	42,94%	45,84%	Benar ditolak
3	Nangka.jpg	Luar kelas	ditolak	Daun Pepaya	49,57%	47,24%	Benar ditolak
4	Alpukat.png	Luar kelas	ditolak	Daun Jambu Biji	94,81%	50,67%	Benar ditolak
5	Salam.png	Luar kelas	ditolak	Daun Sirih	96,60%	46,93%	Benar ditolak
6	Sirsak.png	Luar kelas	ditolak	Daun Sirih	85,36%	47,13%	Benar ditolak
7	Kunyit.JPG	Target	terdeteksi	Daun Kunyit	99,64%	56,21%	Sesuai
8	Lengkuas.png	Luar kelas	ditolak	Daun Kunyit	98,65%	49,64%	Benar ditolak
9	Bangle.png	Luar kelas	ditolak	Daun Kunyit	66,57%	38,42%	Benar ditolak
10	Jahe.png	Luar kelas	ditolak	Daun Jambu Biji	64,05%	33,49%	Benar ditolak
11	Kapulaga.png	Luar kelas	ditolak	Daun Jambu Biji	50,13%	40,03%	Benar ditolak
12	Lempuyang.png	Luar kelas	ditolak	Daun Jambu Biji	91,89%	40,45%	Benar ditolak
13	Pepaya.JPG	Target	terdeteksi	Daun Pepaya	99,75%	61,18%	Sesuai
14	Kapuk Randu.jpg	Luar kelas	ditolak	Daun Pepaya	93,43%	40,50%	Benar ditolak
15	Mentimun.png	Luar kelas	ditolak	Daun Jambu Biji	37,78%	43,72%	Benar ditolak
16	Daun gedi.jpeg	Luar kelas	ditolak	Daun Pepaya	94,97%	39,37%	Benar ditolak
17	Ganja.png	Luar kelas	ditolak	Daun Pepaya	81,42%	48,12%	Benar ditolak
18	Singkong.png	Luar kelas	terdeteksi	Daun Pepaya	76,85%	52,31%	Masih diterima

No	Nama File	Jenis Data	Status	Prediksi SVM	Probabilitas	Kemiripan	Keterangan
19	Sirih.jpg	Target	terdeteksi	Daun Sirih	94,81%	56,68%	Sesuai
20	Waru.jpg	Luar kelas	ditolak	Daun Pepaya	39,16%	37,98%	Benar ditolak
21	Begonia.png	Luar kelas	terdeteksi	Daun Jambu Biji	84,71%	52,18%	Masih diterima
22	Ubi Jalar.png	Luar kelas	terdeteksi	Daun Kunyit	82,92%	57,11%	Masih diterima
23	Talas.png	Luar kelas	ditolak	Daun Sirih	89,77%	46,12%	Benar ditolak
24	Binahong.png	Luar kelas	ditolak	Daun Jambu Biji	67,96%	48,77%	Benar ditolak

Berdasarkan Tabel 4.4, dari 24 citra uji manual terdapat 21 hasil yang sesuai dengan tujuan pengujian. Empat citra target berhasil terdeteksi, sedangkan 17 citra luar kelas berhasil ditolak. Tiga citra luar kelas masih diterima oleh sistem, yaitu Singkong.png, Begonia.png, dan Ubi Jalar.png.

Tabel 4. 5 Citra Luar Kelas yang Masih Terdeteksi

Citra Luar Kelas	Hasil Deteksi	Probabilitas	Kemiripan	Kemungkinan Penyebab
Singkong.png	Daun Pepaya	76,85%	52,31%	Bentuk daun menjari memiliki kedekatan dengan pola bentuk pepaya sehingga melewati ambang kemiripan.
Begonia.png	Daun Jambu Biji	84,71%	52,18%	Sebagian nilai warna dan bentuk mendekati centroid jambu biji.
Ubi Jalar.png	Daun Kunyit	82,92%	57,11%	Nilai kemiripan tertinggi berada pada kelas kunyit sehingga citra masih diterima sistem.

Berdasarkan Tabel 4.7, kesalahan penerimaan terjadi pada tiga citra luar kelas. Singkong.png terdeteksi sebagai daun pepaya karena pola bentuknya mendekati daun pepaya. Begonia.png terdeteksi sebagai daun jambu biji karena nilai fitur warna dan bentuknya cukup dekat. Ubi Jalar.png terdeteksi sebagai daun kunyit karena nilai kemiripan terhadap kelas kunyit melewati ambang. Temuan ini menunjukkan bahwa sistem perlu menambah data luar kelas atau menyesuaikan threshold agar proses penolakan menjadi lebih kuat.

4.2 Pembahasan

Pembahasan digunakan untuk menjelaskan makna dari hasil yang telah diperoleh. Bagian ini menghubungkan hasil evaluasi dengan teori klasifikasi citra, karakteristik fitur daun, dan perilaku sistem saat menerima atau menolak citra uji.

4.2.1 Kinerja Model pada Data Testing

Hasil evaluasi pada data testing menunjukkan bahwa model Multiclass SVM kernel RBF memperoleh akurasi sebesar 96,25%. Nilai ini diperoleh karena dari 80 citra testing, terdapat 77 citra yang berhasil diklasifikasikan dengan benar. Data testing terdiri atas 20 citra daun jambu biji, 20 citra daun kunyit, 20 citra daun pepaya, dan 20 citra daun sirih. Pembagian yang seimbang tersebut membantu penilaian model menjadi lebih adil karena setiap kelas memiliki jumlah data uji yang sama.

Akurasi 96,25% juga dipengaruhi oleh kualitas fitur yang digunakan. Sistem tidak hanya memakai satu jenis ciri, tetapi menggabungkan 26 fitur yang terdiri atas 6 fitur warna HSV, 6 fitur tekstur GLCM, dan 14 fitur bentuk. Fitur warna membantu membaca perbedaan warna daun, fitur tekstur membantu membaca pola permukaan daun, sedangkan fitur bentuk membantu membaca geometri daun. Gabungan fitur ini membuat model memperoleh informasi yang lebih lengkap untuk membedakan empat kelas daun herbal.

Tahap preprocessing juga berpengaruh terhadap hasil tersebut. Citra terlebih dahulu diubah ukurannya menjadi 224 x 224 piksel dan disegmentasi agar objek daun lebih terpisah dari latar belakang. Setelah objek daun lebih jelas, fitur yang dihitung menjadi lebih fokus pada area daun, bukan pada bagian latar belakang. Hal

ini membuat nilai fitur yang masuk ke model menjadi lebih representatif terhadap karakter daun.

Selain itu, penggunaan `StandardScaler` membantu menyeimbangkan rentang nilai fitur. Pada penelitian ini, fitur area dan perimeter memiliki nilai yang jauh lebih besar dibandingkan fitur GLCM atau Hu Moment. Jika fitur tidak dinormalisasi, fitur bernilai besar dapat lebih dominan dalam proses pelatihan. Dengan `StandardScaler`, setiap fitur diubah ke skala yang lebih seimbang sehingga model SVM dapat membaca seluruh fitur secara lebih adil. Penggunaan pipeline dan model machine learning seperti ini sejalan dengan implementasi `scikit-learn` yang digunakan untuk menggabungkan preprocessing dan pelatihan model secara terstruktur.

Pemilihan parameter $C = 10$ dan $\gamma = 0,1$ melalui `GridSearchCV` juga menjadi penyebab akurasi model cukup tinggi. Nilai $C = 10$ membuat model cukup tegas dalam mengurangi kesalahan klasifikasi pada data training, sedangkan $\gamma = 0,1$ membuat pengaruh setiap titik data tidak terlalu sempit dan tidak terlalu luas. Kombinasi ini membantu kernel RBF membentuk batas keputusan yang sesuai dengan sebaran fitur daun. SVM sendiri bekerja dengan mencari hyperplane yang memiliki margin terbaik untuk memisahkan kelas (Cortes & Vapnik, 1995).

Kernel RBF sesuai digunakan karena fitur citra daun tidak selalu membentuk pola linear. Dua daun dapat memiliki warna yang mirip, tetapi bentuknya berbeda. Sebaliknya, dua daun juga dapat memiliki bentuk yang mirip, tetapi tekstur dan warnanya berbeda. Dengan kernel RBF, model dapat membentuk

batas keputusan yang lebih fleksibel sehingga mampu memisahkan kelas yang memiliki pola fitur kompleks. Hasil classification report yang berada pada rentang tinggi menunjukkan bahwa model tidak hanya baik secara umum, tetapi juga cukup seimbang dalam mengenali setiap kelas.

Akurasi yang diperoleh belum mencapai 100% karena masih terdapat beberapa citra testing yang salah diklasifikasikan. Kesalahan tersebut dapat disebabkan oleh kemiripan warna, bentuk, atau tekstur antar daun, variasi pencahayaan, posisi daun, serta hasil segmentasi yang belum sepenuhnya sempurna. Nilai akurasi sebesar 96,25% menunjukkan bahwa model sudah mampu mengenali pola utama pada setiap kelas dengan baik, namun masih memiliki ruang perbaikan terutama pada citra daun yang memiliki karakter visual saling berdekatan.

4.2.2 Peran Fitur Warna Tekstur dan Bentuk

Fitur warna HSV berperan untuk membaca karakter warna daun. Komponen Hue menunjukkan jenis warna, Saturation menunjukkan tingkat kejenuhan warna, sedangkan Value menunjukkan tingkat kecerahan. Penggunaan HSV membantu sistem membaca warna daun dengan lebih jelas karena informasi warna dan kecerahan dipisahkan. Dalam pengolahan citra digital, ruang warna seperti HSV sering digunakan karena lebih mudah digunakan untuk segmentasi dan analisis warna dibandingkan ruang warna RGB pada kondisi pencahayaan yang bervariasi (Gonzalez & Woods, 2018).

Fitur tekstur GLCM berperan untuk membaca pola permukaan daun. GLCM menghitung hubungan antar pasangan piksel pada jarak dan arah tertentu, kemudian

menghasilkan fitur seperti contrast, correlation, energy, homogeneity, dissimilarity, dan ASM. Fitur ini penting karena beberapa daun mungkin memiliki warna yang mirip, tetapi pola permukaannya berbeda (Haralick dkk., 1973)

Fitur bentuk berperan untuk membaca struktur geometri daun. Pada penelitian ini, fitur bentuk dihitung dari kontur hasil segmentasi, seperti area, perimeter, aspect ratio, extent, solidity, circularity, eccentricity, dan Hu Moment. Fitur ini membantu model membedakan daun yang memiliki bentuk khas, misalnya daun pepaya yang menjari, daun kunyit yang memanjang, daun sirih yang menyerupai jantung, dan daun jambu biji yang cenderung elips. Hu Moment digunakan karena mampu mewakili bentuk objek dan relatif stabil terhadap perubahan posisi, ukuran, dan rotasi (Ming-Kuei Hu, 1962).

Gabungan fitur warna, tekstur, dan bentuk membuat sistem memiliki informasi yang lebih lengkap. Jika hanya memakai warna, sistem dapat keliru ketika dua daun memiliki warna hijau yang hampir sama. Jika hanya memakai bentuk, sistem dapat keliru ketika daun luar kelas memiliki bentuk yang mirip dengan daun target. Jika hanya memakai tekstur, sistem juga dapat kesulitan ketika tekstur permukaan daun tidak terlihat jelas karena pencahayaan atau kualitas kamera. Oleh karena itu, ketiga fitur digabungkan agar kelemahan satu fitur dapat dibantu oleh fitur lainnya.

Peran ketiga fitur tersebut juga terlihat pada pengujian manual. Citra target memiliki nilai kemiripan yang cukup tinggi terhadap kelasnya, sedangkan sebagian besar citra luar kelas memiliki nilai kemiripan lebih rendah. Hal ini menunjukkan bahwa fitur visual yang digunakan sudah mampu membedakan karakter daun target

dan daun luar kelas, meskipun beberapa citra luar kelas yang sangat mirip masih dapat melewati ambang keputusan.

4.2.3 Pengujian Manual dan Penolakan Citra Luar Kelas

Pengujian manual dilakukan untuk melihat kemampuan sistem ketika menerima citra yang diunggah langsung. Pengujian ini penting karena penggunaan sistem pada kondisi nyata tidak selalu hanya menerima citra dari empat kelas yang sudah dilatih. Ada kemungkinan pengguna mengunggah daun lain yang bentuk, warna, atau teksturnya mirip dengan kelas target. Oleh karena itu, pengujian manual tidak hanya memakai citra target, tetapi juga memakai citra luar kelas.

Hasil pengujian menunjukkan bahwa semua citra target berhasil terdeteksi. Empat citra target, yaitu Daun jambu biji.JPG, Kunyit.JPG, Pepaya.JPG, dan Sirih.jpg, memperoleh status terdeteksi sesuai kelasnya. Hal ini terjadi karena nilai probabilitas SVM seluruh citra target berada di atas ambang 55%, nilai kemiripan prediksi berada di atas ambang 50%, dan kelas prediksi sama dengan kelas terdekat berdasarkan centroid jadi citra target memiliki pola fitur yang masih dekat dengan data training.

Pada citra luar kelas, sistem berhasil menolak 17 dari 20 citra. Hasil ini menunjukkan bahwa mekanisme penolakan memberi perlindungan tambahan terhadap kesalahan klasifikasi. Jika sistem hanya menggunakan model klasifikasi tertutup, setiap citra luar kelas akan tetap dipaksa masuk ke salah satu dari empat kelas target. Dengan adanya syarat probabilitas, kemiripan, dan konsistensi kelas, sistem menjadi lebih selektif sebelum menerima citra uji.

Keberhasilan uji manual secara keseluruhan mencapai 87,50%, sedangkan kemampuan penolakan citra luar kelas mencapai 85,00%. Nilai ini menunjukkan bahwa sistem cukup baik dalam menghadapi citra target dan citra luar kelas. Hal ini sejalan dengan konsep open set recognition, yaitu sistem pengenalan tidak hanya perlu mengenali kelas yang sudah dipelajari, tetapi juga perlu menghadapi kemungkinan munculnya sampel dari kelas yang belum pernah dilatih (Geng dkk., 2021).

Namun, masih terdapat tiga citra luar kelas yang diterima, yaitu Singkong.png, Begonia.png, dan Ubi Jalar.png. Ketiga citra tersebut memiliki nilai probabilitas dan kemiripan yang melewati ambang keputusan. Singkong.png diterima sebagai daun pepaya karena bentuknya menjari dan mendekati pola daun pepaya. Begonia.png diterima sebagai daun jambu biji karena sebagian fitur warna dan bentuknya mendekati kelas tersebut. Ubi Jalar.png diterima sebagai daun kunyit karena nilai kemiripannya terhadap kelas kunyit melewati ambang. Kondisi ini menunjukkan bahwa citra luar kelas yang sangat mirip masih menjadi tantangan bagi sistem.

Berdasarkan hasil tersebut, mekanisme penolakan sudah membantu, tetapi masih perlu diperkuat. Perbaikan dapat dilakukan dengan menambah data luar kelas sebagai pembanding, memperbanyak variasi citra training, dan menguji nilai threshold yang lebih sesuai. Penguatan ini penting agar sistem tidak terlalu mudah menerima citra yang sebenarnya tidak termasuk dalam data yang telah dilatih.

4.2.4 Analisis Mekanisme Penolakan Citra Luar Kelas

Mekanisme penolakan citra luar kelas pada penelitian ini dibuat karena model klasifikasi biasa cenderung selalu memberikan salah satu label kelas yang tersedia. Pada sistem tertutup, citra daun apa pun akan dipaksa masuk ke kelas jambu biji, kunyit, pepaya, atau sirih. Hal ini dapat menimbulkan kesalahan apabila citra yang diuji sebenarnya bukan berasal dari empat kelas tersebut. Dalam konteks pengenalan citra, masalah ini berkaitan dengan open set recognition, yaitu kondisi ketika sistem harus menghadapi kelas yang tidak tersedia pada data training (Geng dkk., 2021).

Sistem pada penelitian ini menggunakan tiga syarat penolakan. Syarat pertama adalah probabilitas tertinggi dari SVM harus minimal 55%. Syarat ini digunakan untuk melihat keyakinan awal model terhadap kelas prediksi. Syarat kedua adalah kemiripan prediksi harus minimal 50%. Syarat ini digunakan untuk memastikan bahwa citra uji tidak hanya diprediksi sebagai suatu kelas, tetapi juga cukup dekat dengan centroid kelas tersebut. Syarat ketiga adalah kelas prediksi SVM harus sama dengan kelas terdekat berdasarkan nilai kemiripan. Syarat ini digunakan untuk menjaga konsistensi antara hasil model dan kedekatan fitur.

Penggunaan probabilitas saja belum cukup untuk menolak citra luar kelas. Hal ini terlihat pada beberapa citra luar kelas yang memiliki probabilitas cukup tinggi, tetapi tetap berhasil ditolak karena nilai kemiripannya rendah atau tidak konsisten dengan kelas terdekat. Contohnya, citra Salam.png memiliki probabilitas 96,60%, tetapi nilai kemiripannya hanya 46,93%, sehingga sistem menolaknya. Kondisi ini menunjukkan bahwa pemeriksaan jarak terhadap centroid dapat membantu mengurangi keputusan yang terlalu bergantung pada probabilitas SVM.

Nilai kemiripan dihitung dari jarak fitur citra uji terhadap centroid kelas. Jika jarak citra uji dekat dengan centroid kelas, nilai kemiripannya akan lebih tinggi. Sebaliknya, jika jaraknya jauh, nilai kemiripan akan lebih rendah. Hasil pada Tabel 4.6 menunjukkan bahwa citra target memiliki rata-rata probabilitas dan kemiripan sebesar 98,46% dan 59,13%. Citra luar kelas yang ditolak memiliki rata-rata 73,24% dan 43,79%. Perbedaan ini menunjukkan bahwa nilai kemiripan mampu membantu membedakan citra target dan citra luar kelas.

Tabel 4. 6 Ringkasan Analisis Kinerja Uji Manual

Kelompok Data	Jumlah dan Status	Rata-rata Probabilitas/Kemiripan	Makna Hasil
Citra target	4 citra, 4 terdeteksi	98,46% / 59,13%	Citra target dekat dengan centroid kelas data latih sehingga seluruhnya diterima.
Citra luar kelas ditolak	17 citra, 17 ditolak	73,24% / 43,79%	Kemiripan relatif rendah sehingga sistem menolak sebagian besar citra luar kelas.
Citra luar kelas masih diterima	3 citra, 3 terdeteksi	81,49% / 53,87%	Citra luar kelas melewati ambang kemiripan, sehingga sistem masih menerima citra tersebut.

Berdasarkan Tabel 4.6, nilai kemiripan menjadi bagian penting dalam pengambilan keputusan akhir. Citra target memiliki rata-rata kemiripan lebih tinggi dibandingkan citra luar kelas yang ditolak. Namun, tiga citra luar kelas yang masih diterima memiliki rata-rata kemiripan 53,87%, yaitu melewati ambang 50%. Hal ini menunjukkan bahwa threshold kemiripan masih perlu diuji lebih lanjut agar sistem lebih kuat dalam menolak citra luar kelas yang sangat mirip.

Secara umum, mekanisme penolakan pada penelitian ini membuat sistem lebih aman dibandingkan klasifikasi tertutup biasa. Sistem tidak langsung menerima semua citra sebagai salah satu kelas target, tetapi memeriksa kembali apakah citra tersebut benar-benar dekat dengan data yang telah dilatih. Namun,

mekanisme ini masih bersifat sederhana sehingga pengembangan lebih lanjut tetap diperlukan, terutama dengan pendekatan open set recognition yang lebih khusus dan dataset luar kelas yang lebih beragam.

4.2.5 Evaluasi Kinerja dan Keterbatasan Sistem

Evaluasi kinerja dan keterbatasan sistem dilakukan untuk menilai hasil penelitian secara menyeluruh. Evaluasi ini tidak hanya melihat nilai akurasi pada data testing, tetapi juga melihat kemampuan sistem saat digunakan pada pengujian manual.

Berdasarkan hasil pengujian, model Multiclass SVM kernel RBF memperoleh akurasi testing sebesar 96,25%. Nilai tersebut menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra uji dengan benar. Dari 80 citra testing, sebanyak 77 citra berhasil diprediksi sesuai kelasnya, sedangkan 3 citra lainnya masih mengalami kesalahan klasifikasi. Hasil ini menunjukkan bahwa kombinasi fitur HSV, GLCM, fitur bentuk, dan Hu Moment mampu memberikan informasi yang cukup kuat untuk membedakan daun jambu biji, daun kunyit, daun pepaya, dan daun sirih.

Hasil evaluasi pada data testing juga menunjukkan bahwa model memiliki kinerja yang cukup seimbang pada setiap kelas. Hal ini terlihat dari nilai precision, recall, dan f1-score yang berada pada rentang tinggi. Kinerja tersebut dipengaruhi oleh jumlah data yang seimbang pada setiap kelas, proses normalisasi fitur menggunakan StandardScaler, serta pemilihan parameter $C = 10$ dan $\gamma = 0,1$ melalui GridSearchCV. Penggunaan kernel RBF juga membantu model

membentuk batas keputusan yang lebih fleksibel terhadap pola fitur daun yang tidak selalu linear.

Pada pengujian manual, sistem berhasil mendeteksi 4 dari 4 citra target dan menolak 17 dari 20 citra luar kelas. Secara keseluruhan, keberhasilan uji manual mencapai 87,50%, sedangkan kemampuan penolakan citra luar kelas mencapai 85,00%. Hasil ini menunjukkan bahwa sistem tidak hanya mampu mengenali citra dari kelas yang telah dilatih, tetapi juga mulai mampu menolak citra yang tidak sesuai dengan empat kelas target. Mekanisme penolakan melalui probabilitas, kemiripan, dan konsistensi kelas menjadi bagian penting karena dapat mengurangi kemungkinan citra luar kelas langsung diterima sebagai salah satu kelas target.

Meskipun hasil evaluasi cukup baik, sistem masih memiliki beberapa keterbatasan. Pertama, jumlah kelas yang digunakan masih terbatas pada empat jenis daun herbal. Kedua, dataset yang digunakan belum mencakup seluruh variasi kondisi citra, seperti perbedaan pencahayaan, sudut pengambilan gambar, latar belakang, ukuran daun, dan kualitas kamera. Ketiga, mekanisme penolakan citra luar kelas masih menggunakan threshold sederhana, sehingga citra luar kelas yang memiliki kemiripan tinggi masih dapat diterima oleh sistem.

Keterbatasan tersebut terlihat pada tiga citra luar kelas yang masih terdeteksi, yaitu Singkong.png, Begonia.png, dan Ubi Jalar.png. Citra Singkong.png masih diterima karena bentuknya memiliki pola menjari yang mendekati daun pepaya. Citra Begonia.png masih diterima karena sebagian fitur warna dan bentuknya mendekati kelas daun jambu biji. Citra Ubi Jalar.png masih diterima karena nilai kemiripannya terhadap kelas daun kunyit melewati ambang

yang telah ditentukan. Temuan ini menunjukkan bahwa daun luar kelas dengan karakter visual yang sangat mirip masih menjadi tantangan bagi sistem.

Berdasarkan evaluasi tersebut, sistem klasifikasi yang dikembangkan sudah dapat dikatakan bekerja dengan baik untuk mengenali empat jenis daun herbal yang digunakan dalam penelitian. Namun, sistem masih perlu dikembangkan agar lebih kuat saat menghadapi citra luar kelas. Pengembangan dapat dilakukan dengan menambah jumlah data dan kelas tanaman, memperbanyak variasi citra, menguji threshold penolakan yang lebih optimal, serta membandingkan metode SVM dengan metode lain seperti Random Forest, KNN, CNN, atau kombinasi CNN dan SVM. Dengan pengembangan tersebut, sistem diharapkan dapat menghasilkan klasifikasi yang lebih akurat dan lebih siap digunakan pada kondisi nyata.

4.2 Integrasi Islam

Dalam konteks muamalah ma'a Allah, penelitian ini pada hakikatnya merupakan bentuk ibadah dan rasa syukur kepada Allah SWT atas segala nikmat akal pikiran yang telah dianugerahkan kepada manusia. Allah SWT memerintahkan hamba-Nya untuk senantiasa berpikir, mengamati, dan memanfaatkan ciptaan-Nya di muka bumi dengan sebaik-baiknya. Tanaman herbal seperti jambu biji, kunyit, pepaya, dan sirih yang menjadi objek penelitian ini merupakan bagian dari kekayaan alam yang Allah ciptakan untuk kemaslahatan manusia. Hal ini sebagaimana firman Allah SWT dalam QS. Al-An'am ayat 99:

وهو الذي أنزل من السماء ماءً فأخرجنا به نبات كل شيء فأخرجنا منه خضراً نخرج منه حباً متراكباً

Artinya:

“Dan Dialah yang menurunkan air dari langit, lalu Kami tumbuhkan dengan air itu segala macam tumbuh-tumbuhan, maka Kami keluarkan darinya tanaman yang menghijau.” (QS. Al-An'am: 99)

Ayat tersebut menunjukkan bahwa Allah SWT secara langsung menginformasikan kepada manusia tentang keberadaan beragam tumbuhan sebagai tanda kekuasaan-Nya. Pengembangan sistem klasifikasi tanaman herbal berbasis citra daun dalam penelitian ini merupakan wujud nyata dari upaya manusia untuk mengenal, memahami, dan mensyukuri ciptaan Allah. Dengan menggunakan akal dan teknologi yang Allah anugerahkan, peneliti berupaya menciptakan sebuah sistem yang dapat membantu manusia dalam mengidentifikasi tanaman herbal secara tepat dan akurat.

Islam sangat menganjurkan umatnya untuk menuntut ilmu dan mengembangkan pengetahuan demi kebaikan bersama. Rasulullah SAW bersabda bahwa menuntut ilmu adalah kewajiban setiap Muslim. Dalam konteks penelitian ini, pengembangan teknologi klasifikasi daun tanaman herbal menggunakan metode Multiclass Support Vector Machine (SVM) merupakan salah satu bentuk pengamalan perintah tersebut. Setiap proses dalam penelitian, mulai dari pengumpulan data, pengolahan citra, hingga evaluasi model, dilakukan dengan penuh tanggung jawab sebagai bentuk ibadah dan ketaatan kepada Allah SWT.

Selanjutnya, nilai muamalah ma'a an-nas, Penelitian ini tidak hanya berorientasi pada pencapaian akademis semata, tetapi juga memiliki dimensi sosial yang kuat, yaitu memberikan manfaat nyata kepada sesama manusia. Sistem klasifikasi tanaman herbal yang dikembangkan dalam penelitian ini diharapkan dapat membantu masyarakat luas, terutama mereka yang bergantung pada pengobatan tradisional berbasis tanaman herbal, dalam mengidentifikasi jenis tanaman dengan lebih cepat, mudah, dan akurat. Hal ini sejalan dengan prinsip

Islam bahwa sebaik-baik manusia adalah yang paling bermanfaat bagi orang lain.

Allah SWT berfirman dalam QS. Al-Maidah ayat 2:

وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ

Artinya:

“Dan tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan permusuhan.” (QS. Al-Maidah: 2)

Ayat ini mengajarkan pentingnya tolong-menolong dalam kebaikan.

Penelitian ini merupakan bentuk nyata dari tolong-menolong tersebut, khususnya dalam bidang kesehatan masyarakat. Dengan adanya sistem klasifikasi daun herbal yang akurat, masyarakat awam yang tidak memiliki latar belakang botani dapat terbantu dalam mengenali tanaman obat yang mereka butuhkan. Kesalahan identifikasi tanaman herbal yang dapat berujung pada dampak negatif bagi kesehatan pun dapat diminimalkan.

Lebih jauh lagi, penelitian ini juga memberikan kontribusi bagi komunitas ilmiah dan akademisi. Hasil penelitian ini dapat dijadikan referensi bagi peneliti lain dalam mengembangkan sistem serupa, sehingga manfaatnya tidak hanya dirasakan oleh masyarakat umum tetapi juga oleh dunia penelitian. Dalam perspektif Islam, menyebarkan ilmu yang bermanfaat termasuk amal jariyah yang pahalanya terus mengalir.

Dari hal tersebut, pembahasan ini juga berkaitan erat dengan muamalah ma'a al-alam, yaitu alam semesta beserta seluruh isinya, termasuk keanekaragaman tanaman herbal, merupakan amanah dari Allah SWT yang harus dijaga dan dikelola dengan bijaksana oleh manusia sebagai khalifah di bumi. Penelitian ini hadir sebagai bagian dari upaya melestarikan dan mendayagunakan kekayaan hayati

Indonesia secara bertanggung jawab. Allah SWT berfirman dalam QS. Al-A'raf ayat 56:

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ خَوْفًا وَطَمَعًا إِنَّ رَحْمَتَ اللَّهِ قَرِيبٌ مِّنَ الْمُحْسِنِينَ

Artinya:

“Dan janganlah kamu berbuat kerusakan di bumi setelah (diciptakan) dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat kepada orang yang berbuat baik.” (QS. Al-A'raf: 56)

Ayat ini mengajarkan agar manusia tidak membuat kerusakan di bumi dan senantiasa menjaga keseimbangan alam. Penelitian ini secara tidak langsung berkontribusi pada pelestarian alam dengan cara mendorong pemanfaatan tanaman herbal yang lebih terarah dan bertanggung jawab. Ketika masyarakat dapat mengidentifikasi tanaman herbal dengan tepat melalui sistem klasifikasi berbasis teknologi, mereka tidak perlu lagi mencabut atau merusak berbagai jenis tanaman hanya untuk memastikan jenisnya. Proses identifikasi cukup dilakukan melalui foto daun tanpa harus merusak tanaman itu sendiri.

Selain itu, dengan semakin akuratnya sistem identifikasi tanaman herbal, masyarakat akan lebih memahami nilai dan manfaat dari setiap jenis tanaman. Pemahaman ini diharapkan menumbuhkan kesadaran untuk melestarikan tanaman herbal lokal Indonesia yang memiliki nilai ekologi, budaya, dan medis yang tinggi. Dari perspektif Islam, menjaga kelestarian alam bukan sekadar kepedulian lingkungan, melainkan merupakan kewajiban agama sebagai perwujudan tanggung jawab khalifah di bumi.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode Multiclass Support Vector Machine dengan kernel RBF dapat diterapkan untuk mengklasifikasikan tanaman herbal berdasarkan citra daun. Proses klasifikasi dilakukan melalui beberapa tahapan, yaitu resize citra, segmentasi, ekstraksi fitur warna, tekstur, dan bentuk, pelatihan model, evaluasi, serta pengujian manual. Hasil penelitian menunjukkan bahwa model memperoleh parameter terbaik pada nilai $C = 10$ dan $\gamma = 0,1$. Model tersebut menghasilkan akurasi validasi terbaik sebesar 98,75% dan akurasi data testing sebesar 96,25%. Pada tahap pengujian manual, sistem berhasil mendeteksi 4 dari 4 citra target dan mampu menolak 17 dari 20 citra luar kelas. Keberhasilan uji manual mencapai 87,50%, sedangkan kemampuan sistem dalam menolak citra luar kelas mencapai 85,00%.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, saran yang dapat diberikan adalah sebagai berikut.

1. Penelitian selanjutnya sebaiknya menambah jumlah kelas tanaman herbal agar sistem tidak hanya terbatas pada empat jenis daun.
2. Dataset perlu diperbanyak dengan variasi pencahayaan, posisi daun, ukuran daun, latar belakang, dan kualitas kamera yang lebih beragam.

3. Mekanisme penolakan citra luar kelas perlu diperkuat dengan menambahkan data luar kelas, menguji beberapa nilai threshold, atau memakai pendekatan open set recognition.
4. Proses segmentasi citra perlu dikembangkan agar objek daun dapat dipisahkan lebih baik dari latar belakang.
5. Penelitian selanjutnya dapat membandingkan Multiclass SVM dengan metode lain, seperti KNN, Random Forest, CNN, atau kombinasi CNN dan SVM.

Sistem dapat dikembangkan menjadi aplikasi web atau mobile agar pengguna dapat mengunggah foto daun secara langsung.

DAFTAR PUSTAKA

- Agus Supriyanto, R. Rizal Isnanto, & Oky Dwi Nurhayati. (2023). Klasifikasi Penyakit Daun Kopi Robusta Menggunakan Metode SVM dengan Ekstraksi Ciri GLCM. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 12(4), 241–248. <https://doi.org/10.22146/jnteti.v12i4.8044>
- Amriana, A., Ilham, A. A., Achmad, A., & Yusran, Y. (2025). Optimization of Herbal Plant Classification Using Hybrid Method Particle Swarm Optimization With Support Vector Machine. *JOIV: International Journal on Informatics Visualization*, 9(1), 396. <https://doi.org/10.62527/joiv.9.1.2576>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Geng, C., Huang, S.-J., & Chen, S. (2021). Recent Advances in Open Set Recognition: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(10), 3614–3631. <https://doi.org/10.1109/TPAMI.2020.2981604>
- Gonzalez, R. C., & Woods, R. E. (2017). *Digital image processing* (Fourth edition, global edition). Pearson.
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing*. Pearson.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hayatou Oumarou, & Rismayanti, N. (2024). Automated Classification of Empon Plants: A Comparative Study Using Hu Moments and K-NN Algorithm. *Indonesian Journal of Data and Science*, 4(3), 206–214. <https://doi.org/10.56705/ijodas.v4i3.115>
- Ichim, M. C. (2019). The DNA-Based Authentication of Commercial Herbal Products Reveals Their Globally Widespread Adulteration. *Frontiers in Pharmacology*, 10, 1227. <https://doi.org/10.3389/fphar.2019.01227>
- Johari, P. F., Arifin, N., Muzaki, M., & Utama, M. S. A. (2025). Corn Leaf Diseases Classification Using CNN with GLCM, HSV, and L*a*b* Features. *Jurnal Teknik Informatika (Jutif)*, 6(2), 709–722. <https://doi.org/10.52436/1.jutif.2025.6.2.4345>
- Lubis, I., Tommy, & Rosyidah Siregar. (2024). Recognition of Medicinal Plant Leaf Patterns Using Morphology-Based and GLCM Feature Extraction.

Journal of Artificial Intelligence and Engineering Applications (JAIEA), 3(3), 834–839. <https://doi.org/10.59934/jaiea.v3i3.522>

Meo, V. A., Ladopurab, Y. U., & Kaesmetan, Y. R. (t.t.). *Klasifikasi Tanaman Herbal Menggunakan Metode Support Vector Machine*.

Ming-Kuei Hu. (1962). Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, 8(2), 179–187. <https://doi.org/10.1109/TIT.1962.1057692>

Orhan, N., Gafner, S., & Blumenthal, M. (2024). Estimating the extent of adulteration of the popular herbs black cohosh, echinacea, elder berry, ginkgo, and turmeric – its challenges and limitations. *Natural Product Reports*, 41(10), 1604–1621. <https://doi.org/10.1039/D4NP00014E>

Pradipta, I. S., Aprilio, K., Febriyanti, R. M., Ningsih, Y. F., Pratama, M. A. A., Indradi, R. B., Gatera, V. A., Alfian, S. D., Iskandarsyah, A., & Abdulah, R. (2023). Traditional medicine users in a treated chronic disease population: A cross-sectional study in Indonesia. *BMC Complementary Medicine and Therapies*, 23(1), 120. <https://doi.org/10.1186/s12906-023-03947-4>

Prayoga, P. R., Purnawansyah, P., Hasanuddin, T., & Darwis, H. (2023). Klasifikasi Daun Herbal Menggunakan K-Nearest Neighbor dan Support Vector Machine dengan Fitur Fourier Descriptor. *Edumatic: Jurnal Pendidikan Informatika*, 7(1), 160–168. <https://doi.org/10.29408/edumatic.v7i1.17521>

Purnawansyah, P., Wibawa, A. P., Widyaningtyas, T., Haviluddin, H., Hasihi, C. E., Teng, M. F., & Darwis, H. (2023). Comparative Study of Herbal Leaves Classification using Hybrid of GLCM-SVM and GLCM-CNN. *ILKOM Jurnal Ilmiah*, 15(2), 382–389. <https://doi.org/10.33096/ilkom.v15i2.1759.382-389>

Ramli, R., Evanita, E., & Akbar Riadi, A. (2025). Classification of Rice Leaf Diseases Using Support Vector Machine with HSV and GLCM-Based Feature Extraction. *Journal of Applied Informatics and Computing*, 9(5), 2329–2337. <https://doi.org/10.30871/jaic.v9i5.10403>

Szturo, K. (2024). Herbal Plant Classification Using Multi-Feature Extraction and Multilayer Perceptron. *Journal of Computer Science, Information Technology and Telecommunication Engineering*. <https://doi.org/10.30596/jcositte.v5i2.20835>

Vaze, S., Han, K., Vedaldi, A., & Zisserman, A. (2021). *Open-Set Recognition: A Good Closed-Set Classifier is All You Need?* (Versi 2). arXiv. <https://doi.org/10.48550/ARXIV.2110.06207>

LAMPIRAN

No	Skenario Pengujian	Target Skenario	Nama File Asli	Gambar Input	Gambar Segmentasi	Hasil Akhir	Status
1	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Daun jambu biji.JPG			Terdeteksi sebagai Daun Jambu Biji dengan kemiripan 62.45%	terdeteksi
2	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Ketapang.jpg			Bukan dari data yang telah dilatih	ditolak
3	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Nangka.jpg			Bukan dari data yang telah dilatih	ditolak
4	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Alpukat.png			Bukan dari data yang telah dilatih	ditolak
5	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Salam.png			Bukan dari data yang telah dilatih	ditolak
6	Skenario 1 - Mirip Daun Jambu Biji	Daun Jambu Biji	Sirsak.png			Bukan dari data yang telah dilatih	ditolak
7	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Kunyit.JPG			Terdeteksi sebagai Daun Kunyit dengan kemiripan 56.21%	terdeteksi

No	Skenario Pengujian	Target Skenario	Nama File Asli	Gambar Input	Gambar Segmentasi	Hasil Akhir	Status
8	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Lengkuas.png			Bukan dari data yang telah dilatih	ditolak
9	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Bangle.png			Bukan dari data yang telah dilatih	ditolak
10	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Jahe.png			Bukan dari data yang telah dilatih	ditolak
11	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Kapulaga.png			Bukan dari data yang telah dilatih	ditolak
12	Skenario 2 - Mirip Daun Kunyit	Daun Kunyit	Lempuyang.png			Bukan dari data yang telah dilatih	ditolak
13	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Pepaya.JPG			Terdeteksi sebagai Daun Pepaya dengan kemiripan 61.18%	terdeteksi
14	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Kapuk Randu.jpg			Bukan dari data yang telah dilatih	ditolak

No	Skenario Pengujian	Target Skenario	Nama File Asli	Gambar Input	Gambar Segmentasi	Hasil Akhir	Status
15	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Mentimun.png			Bukan dari data yang telah dilatih	ditolak
16	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Daun gedhi.jpeg			Bukan dari data yang telah dilatih	ditolak
17	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Ganja.png			Bukan dari data yang telah dilatih	ditolak
18	Skenario 3 - Mirip Daun Pepaya	Daun Pepaya	Singkong.png			Terdeteksi sebagai Daun Pepaya dengan kemiripan 52.31%	terdeteksi
19	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Sirih.jpg			Terdeteksi sebagai Daun Sirih dengan kemiripan 56.68%	terdeteksi
20	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Waru.jpg			Bukan dari data yang telah dilatih	ditolak
21	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Begonia.png			Terdeteksi sebagai Daun Jambu Biji dengan kemiripan 52.18%	terdeteksi

No	Skenario Pengujian	Target Skenario	Nama File Asli	Gambar Input	Gambar Segmentasi	Hasil Akhir	Status
22	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Ubi Jalar.png			Terdeteksi sebagai Daun Kunyit dengan kemiripan 57.11%	terdeteksi
23	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Talas.png			Bukan dari data yang telah dilatih	ditolak
24	Skenario 4 - Mirip Daun Sirih	Daun Sirih	Binahong.png			Bukan dari data yang telah dilatih	ditolak