

Segmentasi Citra Daun Tomat untuk Klasifikasi Penyakit Tanaman Menggunakan *Support Vector Machine* (SVM)

Puteri Amelia Azli¹, Minarni², Anna Syahrani³, Ganda Yoga Swara⁴, Anisya⁵

^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Teknik, Institut Teknologi Padang
Jln. Gajah Mada Kandis, Nanggalo, Padang, Sumatera Barat, 25143, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-07-23

Revised 2025-09-17

Accepted 2025-09-18

Abstract – Tomatoes are one of the most widely grown crops worldwide. In Indonesia, particularly in West Sumatra, tomato production has declined. This is due to extreme weather conditions and plant disease outbreaks. One solution to help with early identification of tomato plant diseases is through digital image-based classification. This process involves several important stages, starting from image acquisition, preprocessing, segmentation, feature extraction, and classification. However, the quality of classification is highly dependent on the effectiveness of segmentation in separating leaf objects from the background. This study proposes a method for segmenting tomato leaf images based on a combination of color thresholding techniques, morphological operations, contour filtering, and bitwise masking to ensure that only the leaf parts are processed further. After undergoing the segmentation process, images are extracted based on color characteristics in HSV space and GLCM texture, then further processed using an SVM algorithm with an RBF kernel. The dataset used consists of 4000 tomato leaf images with an 80% training and 20% testing data division scheme, accompanied by 5-fold cross validation. The model achieved an accuracy of 96.97% on the training data and 93.75% on the testing data. The results show that segmentation methods using color thresholding, morphology, contours, and bitwise masking can help improve the consistency of extracted features, thereby potentially supporting more stable classification performance.

Keywords: Digital Image Classification; Leaf Image Segmentation; Plant Disease; SVM; Tomato.

Corresponding Author:

Puteri Amelia Azli

Email: puteriazli.it@gmail.com



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak – Tomat merupakan salah satu tanaman yang paling banyak ditanam di seluruh dunia. Di Indonesia, khususnya Sumatera Barat, tomat mengalami penurunan produksi. Penyebabnya adalah faktor cuaca ekstrem dan wabah penyakit tanaman. Salah satu solusi untuk membantu identifikasi dini penyakit tanaman tomat melalui klasifikasi berbasis citra digital. Proses ini melibatkan beberapa tahapan penting, dimulai dari akuisisi citra, preprocessing, segmentasi, ekstraksi fitur, dan klasifikasi. Namun, kualitas klasifikasi sangat bergantung pada efektivitas segmentasi dalam memisahkan objek daun dari latar belakang. Penelitian ini mengusulkan metode segmentasi citra daun tomat berbasis kombinasi teknik *color thresholding*, operasi morfologi, filtering kontur, dan *bitwise masking* untuk memastikan hanya bagian daun yang diproses lebih lanjut. Setelah melalui proses segmentasi, citra diekstrak berdasarkan karakteristik warna dalam ruang HSV dan tekstur GLCM, kemudian diproses lebih lanjut menggunakan algoritma SVM dengan kernel RBF. Dataset yang digunakan terdiri dari 4000 citra daun tomat dengan skema pembagian data 80% untuk latihan dan 20% untuk uji, disertai *cross validation* 5-fold. Model mencapai akurasi 96,97% pada data latihan dan 93,75% pada data uji. Hasil menunjukkan bahwa metode segmentasi dengan *color thresholding*, morfologi, kontur, dan *bitwise masking* dapat membantu meningkatkan konsistensi fitur yang diekstraksi, sehingga berpotensi mendukung performa klasifikasi secara lebih stabil.

Kata Kunci: Klasifikasi Citra Digital, Penyakit Tanaman, Segmentasi Citra Daun, SVM, Tomat.

I. PENDAHULUAN

Tomat merupakan salah satu tanaman yang paling banyak ditanam dan memiliki nilai ekonomi yang signifikan di seluruh dunia [1]. Di Indonesia, tomat merupakan salah satu jenis sayuran populer dan banyak di budidayakan [2], [3]. Hal tersebut karena tanaman tomat dapat tumbuh hampir di semua tanah yang gembur baik dataran tinggi, dataran medium, maupun dataran rendah [4]. Meskipun tomat merupakan komoditas sayuran yang memiliki potensi besar di Indonesia, produksi tanaman ini mengalami penurunan produksi di beberapa daerah, salah satunya adalah Sumatera Barat [5].

Di Sumatera Barat, tanaman sayuran tomat mengalami penurunan produksi sebesar 15.35%. Pada tahun 2022, produksi tomat di Sumatera Barat mencapai 118.635 ton, sementara pada tahun 2023, produksi hanya mencapai 100.429 ton [5]. Penyebabnya adalah kondisi cuaca yang buruk dan dampak dari erupsi Gunung Marapi. Hujan lebat yang berkepanjangan dan erupsi Gunung Marapi menyebabkan kerusakan pada pola tanam dan perkebunan sekitar. Kerusakan tersebut mengakibatkan penurunan hasil panen tomat karena petani yang tinggal di lereng gunung merupakan pemasok utama tomat [6].

Perubahan iklim dapat merusak tanaman secara fisik dan mempengaruhi penyebaran hama serta penyakit tanaman tomat. Suhu dan kelembaban yang lebih tinggi dapat mempercepat pertumbuhan dan perkembangan organisme pengganggu tanaman, serta memperluas wilayah penyebarannya ke daerah-daerah yang sebelumnya tidak terdampak, sehingga dapat meningkatkan serangan penyakit pada tanaman tomat [7], [8].

Petani kesulitan dalam mendiagnosis penyakit tanaman tomat dengan benar karena sulit dilihat secara kasat mata dan tidak dapat diidentifikasi dengan mudah [9], [10]. Hal tersebut karena gejala yang muncul pada tahap awal infeksi umumnya bersifat samar. Kemiripan visual antar penyakit juga menyebabkan petani kesulitan membedakan jenis penyakit tanaman tomat [11]. Menggunakan pengamatan visual juga sangat bergantung pada pengalaman petani atau tenaga ahli. Sementara pengamatan visual oleh petani atau tenaga ahli bersifat subjektif dan sulit diukur secara konsisten [12]. Selain itu, proses diagnosis visual juga cenderung memerlukan tenaga ahli, biaya yang mahal, dan rentan terhadap kesalahan akibat kelelahan atau bias persepsi manusia [13]. Hal tersebut dapat menyebabkan kesalahan dalam penanganan, seperti penggunaan jenis atau dosis pestisida yang tidak sesuai dan akhirnya berdampak negatif terhadap kesehatan tanaman tomat [14]. Padahal, penggunaan pestisida yang tepat dan proporsional sangat berpengaruh terhadap produktivitas dan kualitas hasil panen tomat [15].

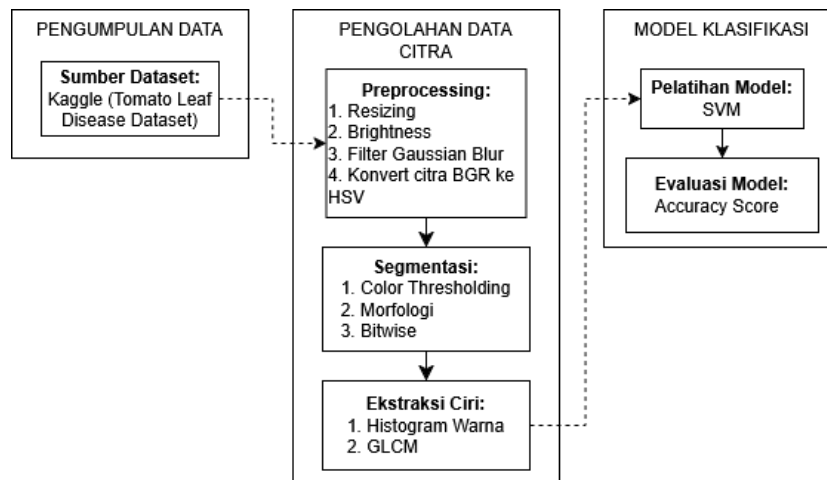
Kecerdasan buatan merupakan salah satu teknologi cerdas yang dapat membantu petani dalam mengurangi kesalahan dalam deteksi penyakit pada tanaman tomat [8], [16]. Penelitian menunjukkan bahwa metode pendeteksian penyakit pada tanaman tomat yang cepat dan efisien adalah klasifikasi dengan media citra. Media gambar diambil menggunakan instrumen elektronik, yang kemudian menghasilkan gambar digital [17]. Namun, untuk mendapatkan citra digital yang berkualitas, diperlukan teknik untuk mengolah citra digital tersebut. Tahap-tahap dalam mengolah citra digital dimulai dari akuisisi data, *preprocessing*, segmentasi, dan ekstraksi ciri [18]. Pengolahan citra dilakukan untuk meningkatkan kualitas citra yang berperan dalam akurasi model klasifikasi [19].

Pada penelitian terdahulu, oleh Sadri Talib, Sakina Sudin, dan Muhammad Dzirkullah Suratn melakukan klasifikasi jenis cengkeh menggunakan algoritma SVM dengan fitur tekstur berbasis *Gray Level Co-occurrence Matrix* (GLCM), namun hanya menggunakan empat parameter (kontras, korelasi, energi, dan homogenitas) dan tidak melibatkan informasi warna daun maupun segmentasi objek daun secara eksplisit [20]. Penelitian oleh Hamdan Pratama menggunakan metode *Linear Discriminant Analysis* (LDA) pada citra buah sukun dengan ekstraksi fitur warna dan tekstur, namun segmentasi objek tidak dilakukan secara mendalam, hanya sebatas konversi warna citra [21]. Muhammad Ghudafa Taufik Akbar dan Henny Leidiyana mengklasifikasikan citra bunga menggunakan metode histogram warna dan beberapa algoritma klasifikasi, termasuk SVM, namun *preprocessing* terbatas pada konversi ruang warna tanpa segmentasi objek [22]. Sementara itu, Puerwandono dan Irfan Maulana melakukan klasifikasi citra daun sirih menggunakan algoritma SVM dengan fitur warna, tekstur, dan bentuk, serta segmentasi menggunakan *K-means clustering*, yang memiliki keterbatasan dalam memisahkan objek dengan latar belakang kompleks seperti daun tomat [23]. Luh Putu Risma Noviana dan Nyoman Bagus Suweta Nugrahah membandingkan klasifikasi citra daun herbal menggunakan metode *Logistic regression* dan *Decision tree classifier* berdasarkan fitur warna, GLCM, dan bentuk namun tidak melakukan segmentasi citra [24]. Joko Riyono, Christina Eni Pujiastuti, Sofia Debi Puspa, Supriyadi, dan Fayza Nayla Riyana Putri meningkatkan klasifikasi penyakit paru-paru Melalui *K-means clustering*, segmentasi *Chan-vee*, dan deteksi tepi Canny pada citra tersegmentasi x-ray [25]. Farida Amalya dan Silvia Harlena mengklasifikasi buah berkhasiat obat menggunakan algoritma *Euclidean Distance* dengan metode segmentasi *K-means Clustering* [26]. Tujuan dari penelitian ini adalah untuk menilai dampak segmentasi terhadap akurasi SVM pada 4 kelas penyakit daun tomat.

Pada penelitian ini, diusulkan pendekatan klasifikasi penyakit daun tomat berbasis SVM yang dilengkapi dengan teknik *preprocessing* dan segmentasi berlapis. Segmentasi dilakukan melalui kombinasi HSV *multi-thresholding* tiga rentang warna, pembersihan morfologi beriterasi, *filtering* kontur dengan kriteria area dan *aspect ratio*, serta *bitwise masking* untuk menghasilkan segmentasi daun yang lebih bersih. Tahap ini dilakukan untuk memastikan bahwa fitur warna dan tekstur yang diekstraksi benar-benar berasal dari objek daun, bukan latar belakang, sehingga fitur yang digunakan untuk klasifikasi menjadi lebih relevan. Selain itu, kombinasi fitur warna berbasis histogram HSV (*Hue*, *Saturation*, *Value*) dan tekstur berbasis GLCM (*Gray Level Co-occurrence Matrix*) digunakan untuk menangkap informasi visual daun secara lebih lengkap. Perbedaan penelitian ini dibanding studi sebelumnya terletak pada tiga kontribusi utama, yaitu pengembangan rangkaian segmentasi berlapis yang secara khusus menyoroti variasi warna daun, pemanfaatan kombinasi fitur HSV dan GLCM yang ringkas tetapi komprehensif, serta evaluasi model dengan skema pembagian data 80% untuk latihan dan 20% untuk uji, serta *cross validation* 5-fold untuk menghasilkan pengukuran kinerja yang lebih terukur dan reliabel. Dengan demikian, penelitian ini diharapkan dapat menghadirkan pendekatan klasifikasi penyakit daun tomat yang lebih konsisten dan dapat diandalkan. Penelitian ini diharapkan mampu menghasilkan akurasi klasifikasi yang lebih baik dibandingkan penelitian sebelumnya.

II. METODE


Tahapan penelitian dimulai dari mengumpulkan data secara *online* melalui sumber data publik. Data yang diperoleh dari sumber tersebut kemudian diolah dengan teknik pengolahan data citra seperti *preprocessing*, segmentasi, dan ekstraksi ciri. Hasil yang diperoleh dari ekstraksi ciri dijadikan masukan untuk membangun model klasifikasi yang mencakup pelatihan dan evaluasi model SVM. Tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Dataset

Dataset yang digunakan dalam penelitian ini adalah data sekunder berupa citra daun tomat yang diambil dari Kaggle (<https://www.kaggle.com/datasets/ahmadzargar/tomato-leaf-disease-dataset-segmented>). Dataset ini bersifat *open-access* dengan lisensi publik yang memperbolehkan penggunaan untuk tujuan penelitian akademik, tanpa memerlukan izin tambahan. Dataset masih berupa citra mentah (*raw*), yaitu belum melalui proses segmentasi. Jumlah data yang digunakan untuk penelitian ini adalah sebanyak 4000 citra, dengan 4 kategori kondisi daun tomat yang masing-masing kategori berjumlah 1000 citra. Kategori tersebut adalah busuk daun, jamur daun, sehat, dan septoria. Dimensi tiap citra adalah 256x256 piksel dengan tipe data JPG dan memiliki latar belakang yang cukup bervariasi. Contoh sampel data penelitian dapat dilihat pada Gambar 2.



Gambar 2. Sampel Datas Daun Tomat

B. Preprocessing

Preprocessing merupakan tahapan untuk mempersiapkan sampel data sebelum diproses lebih lanjut. Ditahap ini, data yang sudah berupa citra digital akan dilakukan serangkaian tahapan *preprocessing* dengan tujuan untuk mengoptimalkan tahapan segmentasi. Rangkaian *preprocessing* mencakup *resizing*, peningkatan *brightness* sebesar 5 pada setiap kanal, filter *gaussian blur* dengan kernel 7x7, dan konversi warna citra RGB ke HSV.

Langkah pertama dalam tahap *preprocessing* adalah mengubah ukuran citra (*resizing*) untuk menyeragamkan ukurannya. Dalam penelitian ini, ukuran citra diubah menjadi 512x512 piksel. Hal tersebut dilakukan untuk meningkatkan kualitas representasi tekstur pada proses pelatihan model. Pertimbangan ini dilakukan karena resolusi citra yang lebih tinggi dapat membantu model mengenali pola halus pada daun seperti tekstur bercak atau pola jamur, meskipun berisiko menimbulkan artefak interpolasi. Langkah selanjutnya adalah melakukan peningkatan *brightness* dengan menambahkan nilai intensitas piksel sebanyak 5 pada setiap kanal warna. Hal tersebut dilakukan karena terdapat beberapa citra dengan pencahayaan yang kurang merata dan

memiliki bayangan pada objek serta latar belakang (*background*). Setelah melakukan peningkatan *brightness*, akan diterapkan efek buram pada citra menggunakan *Gaussian blur* dengan ukuran kernel 7x7 piksel. Efek buram diterapkan dengan tujuan untuk mengurangi *noise* dengan menyamarkan detail latar belakang yang tidak relevan, sehingga proses segmentasi objek daun dapat dilakukan dengan lebih optimal [27]. Setelah diberi efek buram dengan *Gaussian blur*, citra akan dikonversi dari ruang warna RGB menjadi ruang warna HSV untuk mempermudah pemisahan warna daun dan *background*. Pemilihan ruang warna HSV pada penelitian ini didasarkan pada karakteristik data yang digunakan, di mana setiap citra memiliki *background* dan pencahayaan yang berbeda. HSV digunakan karena kelebihanannya yang lebih stabil terhadap perubahan cahaya dibandingkan dengan ruang warna RGB, serta memudah proses pemisahan warna daun dari latar belakang.

C. Segmentasi

Segmentasi merupakan tahap penting dalam analisis citra. Tujuan dari segmentasi yaitu memisahkan objek daun dari *background* dan membantu menghilangkan bagian yang tidak diperlukan, sehingga fitur yang diekstraksi lebih relevan untuk proses klasifikasi. Pada penelitian ini, proses segmentasi meliputi *color thresholding*, penggabungan *mask*, operasi morfologi, *filtering* kontur, dan *bitwise masking*. Tahapan segmentasi dapat dilihat pada Gambar 3.



Gambar 3. Tahapan segmentasi

Langkah awal dalam tahapan segmentasi adalah melakukan rentang warna daun dengan *color thresholding* dalam ruang warna HSV. Hal ini dilakukan dengan menentukan nilai batas bawah dan batas atas daun. Penentuan rentang nilai tersebut dilakukan secara manual dengan mengamati nilai H, S, dan V *background* citra. Rentang nilai tersebut digunakan untuk memisahkan objek daun dan *background* sesuai dengan variasi warna. Terdapat tiga rentang warna yang digunakan pada penelitian ini, yaitu hijau, coklat, dan kuning. Rentang warna dilakukan secara terpisah agar hasil segmentasi daun menjadi lebih tepat sesuai dengan variasi warna. Nilai dari rentang warna tersebut dapat dilihat pada Tabel 1.

TABEL 1
 RENTANG NILAI *COLOR THRESHOLDING*

Warna	Hue	Saturation	Value
Hijau	35-90	30-255	30-255
Coklat	10-80	30-255	10-255
Kuning	15-40	50-255	40-255

Selanjutnya, akan dibuatkan *mask* dari masing-masing warna berdasarkan rentang warna yang telah ditentukan. Setelah itu, hasil *mask* dari ketiga warna tersebut akan digabung menjadi satu dengan menggunakan operator logika OR dengan fungsi *bitwise OR*. Tujuannya adalah untuk menghasilkan satu citra biner yang merepresentasikan area daun secara keseluruhan dari ketiga rentang warna yang telah ditentukan sebelumnya. Metode *bitwise* dipilih karena efektif dalam memisahkan objek dari latar belakang tanpa menghilangkan informasi penting dari masing-masing warna.

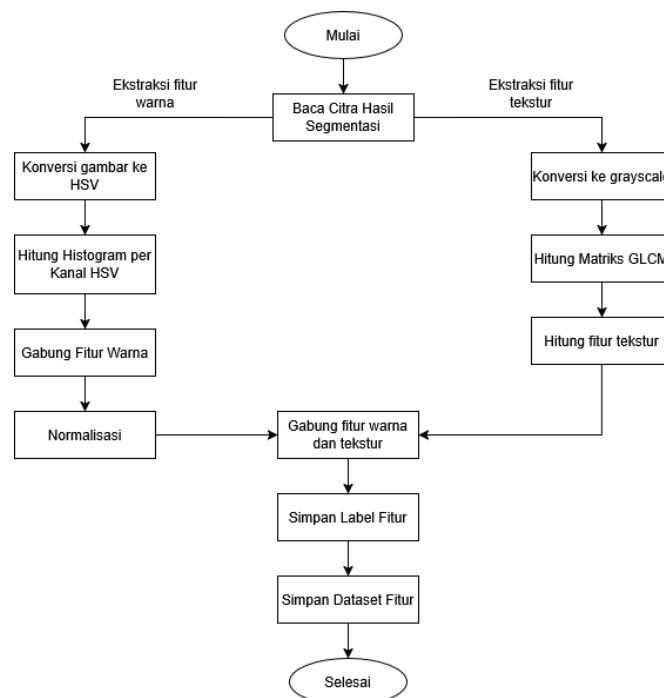
Setelah menggabungkan hasil *mask color thresholding*, dilanjutkan dengan melakukan pembersihan *noise* dengan teknik morfologi. *Noise* yang dimaksudkan dalam penelitian ini adalah bagian *background* citra yang ikut tersegmentasi. Pada penelitian ini, jenis kernel yang akan digunakan adalah *morph ellipse (elliptical)* berukuran 5x5 piksel. Urutan operasi yang dilakukan adalah *opening* diikuti *closing* dengan 2 pengulangan (iterasi). Morfologi *opening* dilakukan untuk mengikis bagian putih pada citra dan kemudian mengembangkan kembali bagian putih yang tersisa ke bentuk semula, kemudian morfologi *closing* akan memperbesar objek putih untuk menutup lubang kecil hitam di dalam daun dengan teknik dilasi dan mengembalikan bentuk objek ke ukuran semula dengan lubang yang sudah tertutup dengan teknik erosi. *Morph ellips* dipilih dalam penelitian ini karena lebih cocok untuk citra daun yang bersifat melengkung.

Selanjutnya akan dilakukan *contour filtering (filtering kontur)* pada gambar hasil proses morfologi untuk memilah kontur yang penting seperti daun dan membuang yang tidak penting seperti *noise*, bayangan, atau sisa *background*. Kriteria filter yang digunakan adalah luas kontur minimum sebesar 2500 piksel dan rentang *aspect ratio* antara 0,1 hingga 3,0. Pemilihan nilai tersebut dilakukan dengan beberapa eksperimen untuk menyesuaikan dengan data citra yang digunakan.

Langkah terakhir dari segmentasi adalah melakukan *bitwise masking* untuk mengambil bagian objek daun tomat dari citra asli. Citra hasil *bitwise masking* tersebut akan disimpan dalam ruang warna RGB untuk mempermudah proses pada tahap selanjutnya, yaitu ekstraksi fitur warna dan tekstur. Untuk menerapkan *bitwise masking*, ukuran citra dan *mask* harus sama, sudah melalui tahap *thresholding* dan morfologi, serta fungsi yang digunakan adalah fungsi *bitwise AND*.

D. Ekstraksi Fitur

Setelah melalui tahapan segmentasi, akan dilakukan ekstraksi fitur terhadap citra. Tujuannya adalah untuk mengambil informasi penting dari citra agar algoritma SVM dapat membedakan jenis-jenis penyakit tanaman tomat. Fitur-fitur yang diekstraksi berupa fitur warna dan tekstur. Fitur warna diperoleh melalui histogram warna pada ruang HSV, dengan pembagian jumlah bin 8-8-8 untuk kanal H, S, dan V, sehingga menghasilkan total 24 nilai fitur. Histogram kemudian dinormalisasi agar nilai distribusi berada pada rentang yang seragam, sehingga tidak terjadi bias akibat perbedaan jumlah piksel. Sedangkan fitur tekstur diperoleh menggunakan metode GLCM. Citra terlebih dahulu diubah menjadi skala keabuan dengan 256 tingkat keabuan. GLCM dihitung dengan jarak 1 piksel pada empat orientasi sudut, yaitu 0°, 45°, 90°, dan 135°, untuk merepresentasikan variasi arah tekstur pada citra, kemudian dibuat simetris dan dinormalisasi. Dari masing-masing GLCM dihitung empat metrik utama, yaitu: *contrast*, *correlation*, *energy*, dan *homogeneity*, sehingga diperoleh 4 fitur tekstur. Dengan demikian, total fitur yang digunakan dalam penelitian ini adalah 28 fitur yang terdiri dari 24 fitur warna dan 4 fitur tekstur. Fitur-fitur tersebut selanjutnya dijadikan masukan pada tahap klasifikasi menggunakan algoritma SVM. Tahapan ekstraksi fitur ditunjukkan pada Gambar 4.



Gambar 4. Tahapan Ekstraksi Fitur

E. Klasifikasi dengan SVM

Data citra yang dihasilkan dari ekstraksi fitur akan diklasifikasi menggunakan algoritma SVM [28]. Parameter yang digunakan dalam penelitian ini adalah kernel RBF dengan gamma berjenis *scale* dan regulasi (C) bernilai 10. Seluruh fitur terlebih dahulu dilakukan standarisasi menggunakan *StandardScaler* agar memiliki distribusi dengan rata-rata 0 dan variansi 1, karena performa SVM sensitif terhadap perbedaan skala fitur. Model dilatih dengan skema pembagian data 80% untuk pelatihan dan 20% untuk pengujian menggunakan teknik *train-test split* disertai dengan *stratification*. Pada subset data latih, diterapkan *5-fold cross-validation* untuk mengevaluasi stabilitas model. Hasil validasi dilaporkan dalam bentuk rata-rata akurasi beserta deviasi standarnya. Setelah model terbaik diperoleh dari hasil *cross-validation*, model kemudian diuji pada data uji yang benar-benar terpisah untuk memperoleh performa akhir. Evaluasi performa model dilakukan dengan menggunakan metrik evaluasi *confussion matrix*, *classification report*, dan *accuracy score* untuk mengukur seberapa baik model dapat memprediksi data. Rumus perhitungan akurasi ditunjukkan dalam Persamaan (1) sampai Persamaan (5) [12], [29].

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$F1 - \text{score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

$$\text{Accuracy Score} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

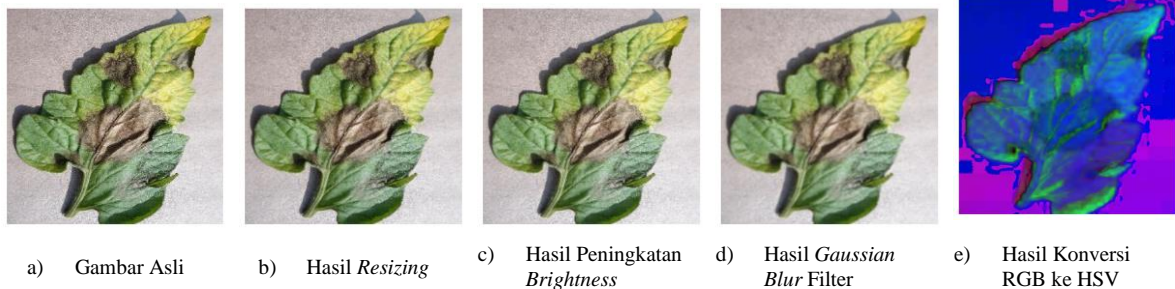
Pada persamaan di atas, TP adalah jumlah *true positive*, TN adalah jumlah *true negative*, FP adalah jumlah *false positif*, dan FN adalah jumlah *false negative*.

III. HASIL DAN PEMBAHASAN

Bagian berikut ini akan membahas mengenai hasil yang diperoleh dari penelitian yang telah dilakukan. Hasil dan Pembahasan difokuskan pada teknik *preprocessing*, segmentasi, evaluasi algoritma SVM, dan peran segmentasi terhadap performa klasifikasi penyakit daun tomat menggunakan SVM.

A. Hasil Preprocessing

Preprocessing akan dilakukan pada citra daun tomat yang diperoleh dari Kaggle. Teknik *preprocessing* yang dilakukan pada penelitian ini dapat memperbaiki citra. Teknik *resizing* berhasil mengubah dan menyamakan ukuran seluruh citra yang sebelumnya 256x256 piksel menjadi 512x512 piksel. Teknik peningkatan *brightness* berhasil meningkatkan kecerahan citra yang sebelumnya kurang merata dan memiliki bayangan pada objek dan *background*. Teknik *gaussian blur* filter dapat mengurangi *noise* seperti detail latar belakang yang samar tanpa menghilangkan bentuk objek daun. Konversi warna citra dari RGB ke HSV efektif untuk memisahkan objek dan *background* berdasarkan intensitas warna. Hasil teknik *preprocessing* dapat dilihat pada Gambar 5.



Gambar 5. Hasil Teknik *Preprocessing*


B. Hasil Segmentasi

Segmentasi dilakukan pada citra daun tomat yang telah melalui tahap *preprocessing*. Gabungan dari proses segmentasi yang dilakukan pada penelitian ini dapat memisahkan antara objek dan *background* pada citra. Penggabungan hasil *mask* dari rentang warna *color thresholding* dapat memisahkan objek daun dan *background* sesuai dengan variasi warna pada sebagian besar dataset. Namun, beberapa citra masih memiliki *noise* dan lubang hitam pada objek daun. Untuk itu, diperlukan proses segmentasi selanjutnya untuk menyempurnakan hasil segmentasi. Hasil *mask color thresholding* tersebut dapat dilihat pada Gambar 6.



Gambar 6. Hasil Penggabungan Mask Color Thresholding

Setelah melakukan penggabungan hasil *mask color thresholding*, dilakukan teknik morfologi untuk membersihkan *noise* yang masih tersisa dan membantu menutup lubang hitam pada objek daun. Pada sebagian besar data, operasi morfologi *open* dan *close* memberikan hasil yang positif dalam membersihkan *noise* dan menutup lubang kecil hitam pada objek daun. Namun, masih terdapat beberapa citra yang masih belum sempurna. Untuk itu, perlu dilakukan tahapan selanjutnya. Hasil dari proses morfologi dapat dilihat pada Gambar 7.



Gambar 7. Hasil Proses Morfologi *Open* dan *Close*

Setelah melakukan morfologi, selanjutnya akan dilakukan *contour filtering* (kontur). Hasil penerapan kontur dengan parameter 2500 dan aspek 0.1 hingga 3.0 berhasil memilah kontur penting seperti daun dan membuang yang tidak penting seperti *noise*, bayangan, atau sisa *background* pada sebagian besar data. Beberapa data masih memiliki *noise* dan beberapa lainnya tidak terkontur dengan baik. Hasil dari proses kontur dapat dilihat pada Gambar 8.



Gambar 8. Hasil Proses Kontur

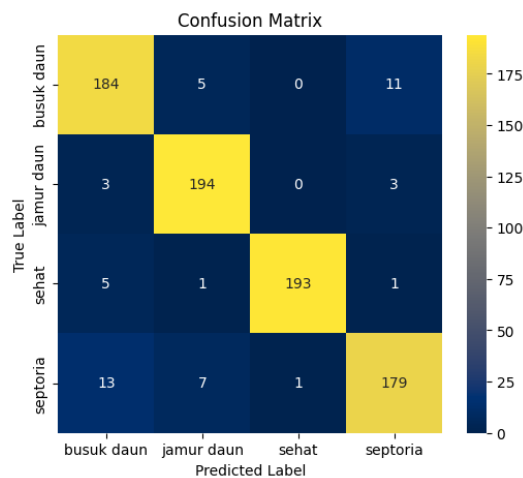
Langkah terakhir yang dilakukan adalah *bitwise masking*. Hasil yang didapat yaitu *bitwise masking* dengan menggunakan *bitwise AND* menghasilkan segmentasi yang optimal pada sebagian besar data, meskipun masih terdapat beberapa data citra yang tidak tersegmentasi dengan sempurna seperti masih memiliki *background* yang ikut tersegmentasi dan objek daun tidak lengkap atau terpotong. Citra hasil *bitwise masking* selanjutnya akan diproses dalam ekstraksi fitur. Hasil dari proses *bitwise masking* dapat dilihat pada Gambar 9.



Gambar 9. Hasil *Bitwise AND*

C. Evaluasi klasifikasi SVM.

Berdasarkan hasil evaluasi model SVM untuk klasifikasi penyakit tanaman tomat dengan *confussion matrix*, *classification report* dan *accuracy score*, didapatkan performa model seperti pada Gambar 10, Tabel 2 dan Gambar 11.



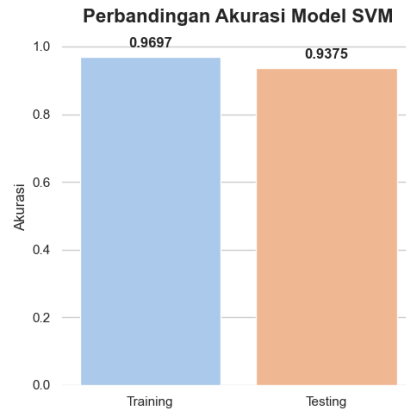
Gambar 10. Hasil Evaluasi *Confussion Matrix*

Berdasarkan Gambar 10, hasil evaluasi *confussion matrix* menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra dengan tepat, ditunjukkan oleh nilai *True Positive* (TP) yang tinggi pada setiap kelas, seperti 184 untuk kelas busuk daun, 194 untuk jamur daun, 193 untuk sehat, dan 179 untuk septoria. Nilai tersebut merepresentasikan jumlah prediksi yang benar pada masing-masing kelas, sedangkan kesalahan prediksi relatif kecil dan umumnya terjadi pada kelas busuk daun dan septoria.

TABEL 2
HASIL EVALUASI *CLASSIFICATION REPORT*

Kategori	Precision	Recall	F1-Score	Support
busuk daun	0.90	0.92	0.91	200
jamur daun	0.94	0.97	0.95	200
sehat	0.99	0.96	0.98	200
septoria	0.92	0.90	0.91	200

Berdasarkan Tabel 2, hasil *classification report* memperlihatkan bahwa kelas sehat dan jamur daun memiliki performa terbaik dengan nilai *precision* dan *recall* di atas 0,95, sedangkan kelas busuk daun dan septoria memiliki *recall* lebih rendah, yaitu 0,92 dan 0,90. Hal tersebut menandakan bahwa adanya kesalahan prediksi silang antar kedua kelas. Hal ini juga tampak pada *confussion matrix* di mana beberapa sampel busuk daun salah diprediksi sebagai septoria, dan sebaliknya. Kesalahan prediksi tersebut kemungkinan besar disebabkan oleh kemiripan fitur atau gejala penyakit pada kedua kelas tersebut.



Gambar 11. Hasil Evaluasi Accuracy Score

Berdasarkan Gambar 11, hasil *accuracy score* menunjukkan bahwa performa keseluruhan model SVM dengan kernel kernel RBF, $C=10$ dan $\gamma=scale$ memperoleh akurasi sebesar 96,97% pada data latih dan 93,75% pada data uji. Selisih yang relatif kecil ini menunjukkan kemampuan generalisasi yang baik serta risiko *overfitting* yang rendah. Selain itu, evaluasi menggunakan 5-fold *cross-validation* pada data latih menghasilkan rata-rata akurasi sebesar $91,88\% \pm 1,10$. Variasi antar *fold* relatif kecil, menandakan bahwa model stabil dan tidak terlalu sensitif terhadap perbedaan *subset* data latih.

Meskipun tidak dilakukan perbandingan langsung antara citra yang disegmentasi dan yang tidak, segmentasi berperan penting dalam memastikan bahwa fitur yang diekstraksi berasal dari area yang benar-benar merepresentasikan objek daun. Segmentasi membantu menghilangkan bagian citra yang tidak relevan seperti latar belakang, bayangan, dan *noise* lain, yang secara potensial dapat mengganggu proses ekstraksi fitur dan klasifikasi. Dengan fokus hanya pada objek daun, fitur warna dan tekstur yang diambil menjadi lebih konsisten dan deskriptif. Hal ini secara tidak langsung mendukung performa model SVM dalam mengenali pola visual dari masing-masing kelas penyakit [30].

D. Perbandingan Studi Literatur

Berbagai studi terdahulu telah mengkaji pendekatan dalam segmentasi dan klasifikasi citra digital, khususnya pada objek-objek berbasis tanaman dan buah. Beberapa rangkuman studi yang relevan beserta detail metode, dataset, dan akurasi yang dicapai dapat dilihat pada Tabel 3.

TABEL 3
STUDI LITERATUR

No	Referensi	Dataset	Segmentasi	Klasifikasi	Akurasi
1	Sadri Talib (2024)	Latih: 150 Uji: 60	-	SVM	56.67%
2	Hamdan Pratama (2024)	Latih: 1400 Uji: 600	-	LDA	Latih: 89,71% Uji: 89,93%
3	Muhammad Ghudafa Taufik Akbar (2023)	<i>Cross Validation</i> , $k=10$	-	- <i>Logistic Regression</i> - <i>Decision Tree</i> - <i>Random Forest</i> - KNN - LDA - <i>Naive Bayes</i> - SVM	<i>Logistic Regression</i> : 70% <i>Decision Tree</i> : 70% <i>Random Forest</i> : 82% KNN: 64% LDA: 66% <i>Naive Bayes</i> : 43% SVM: 70%
4	Edhy Puerwandono (2023)	Latih: 1400 Uji: 600	<i>K-means clustering</i>	SVM	Latih: 91% Uji: 80%
5	Luh Putu Risma Noviana (2023)	Latih: 275	-	- <i>Logistic Regression</i> - <i>Decision Tree Classifier</i>	- <i>Logistic Regression</i> Latih: 72,9% Uji: 60,24% - <i>Decision Tree Classifier</i> Latih: 100% Uji: 78,31%
6	Joko Riyono (2024)	2852	- <i>Chan-Vese segmentation</i>	<i>K-means Clustering</i>	80%

			–	<i>Canny edge detection</i>	
7	Farida Amalya (2022)	Latih: 120 Uji: 120	K-means clustering	<i>Euclidean distance</i>	83,33%
8	Penelitian yang diusulkan	Latih: 3200 Uji: 800	–	Color thresholding – Morfologi – Kontur – Bitwise AND	SVM Latih: 96,97% Uji: 93,75%

Berdasarkan hasil perbandingan studi literatur pada Tabel 3, sebagian besar penelitian sebelumnya masih menitikberatkan pada tahap klasifikasi tanpa mengoptimalkan proses segmentasi secara menyeluruh. Beberapa studi bahkan tidak menggunakan metode segmentasi sama sekali, seperti pada penelitian Sadri Talib yang hanya memperoleh akurasi 56,67% [20], Hamdan Pratama yang mencapai akurasi 89,71% pada data latih dan 89,93% pada data uji [21]. Muhammad Ghudafa Taufik Akbar yang menguji beberapa algoritma klasifikasi dengan akurasi tertinggi sebesar 82% [22], serta Luh Putu Risma Noviana yang menggunakan dua pendekatan klasifikasi dengan akurasi tertinggi yang didapat yaitu 100% pada data latih dan 78,31% pada uji [24]. Perbedaan hasil akurasi latih dan uji yang cukup tinggi tersebut menunjukkan adanya indikasi *overfitting*. Terdapat beberapa studi yang sudah menerapkan segmentasi, seperti pada penelitian Edhy Puerwandono yang menggunakan segmentasi dengan *K-means clustering* menghasilkan akurasi 91% untuk data latih dan 80% untuk uji [23]. Joko Riyono yang menggunakan kombinasi segmentasi *Chan-Vese segmentation* disertai dengan *canny edge detection* menghasilkan akurasi sebesar 80% [25] serta Farida Amalya yang juga menggunakan *K-means clustering* dan menghasilkan akurasi klasifikasi sebesar 83,33% [26]. *K-means clustering* dapat memisahkan objek utama dari latar belakang, tetapi sering menghasilkan *cluster* yang kurang konsisten pada tepi daun. Sementara Chan–Vese, metodenya lebih presisi, tetapi kompleksitas komputasinya relatif tinggi, sehingga kurang efisien untuk dataset berskala besar. Berbeda dengan penelitian-penelitian tersebut, penelitian ini mengusulkan pendekatan segmentasi berlapis dengan multi-*thresholding* HSV dengan tiga rentang warna, operasi morfologi, *filtering* kontur, dan *bitwise masking*. Strategi ini lebih ringan secara komputasi dibandingkan metode Chan–Vese namun menghasilkan fitur warna dan tekstur yang lebih konsisten dibandingkan segmentasi berbasis *clustering*. Hal ini terbukti mampu meningkatkan performa klasifikasi SVM hingga akurasi 96,97% pada data latih dan 93,75% pada data uji.

Sebagai sintesis, dapat disimpulkan bahwa masih terdapat celah metodologis pada penelitian terdahulu, terutama terkait pentingnya segmentasi menyeluruh untuk menjaga konsistensi fitur yang diekstraksi. Oleh karena itu, penelitian ini juga menyertakan *ablation study* untuk membuktikan kontribusi setiap tahapan segmentasi terhadap peningkatan kinerja klasifikasi, sekaligus memberikan justifikasi yang lebih kuat terhadap rancangan metode yang diusulkan. Hasil *ablation study* dapat dilihat pada Tabel 4.

TABEL 4
HASIL ABLATION STUDY PADA PIPELINE SEGMENTASI

Tahap yang Digunakan	Akurasi Latih	Akurasi Uji	5-fold CV	Std	Waktu
Gabungan multi-<i>thresholding</i> tiga warna + <i>bitwise masking</i>	97,06%	91,87%	91,25%	0.010	7 menit 31 detik
Gabungan multi-<i>thresholding</i> tiga warna + morfologi + <i>bitwise masking</i>	97,50%	92,63%	91,37%	0.014	5 menit 56 detik
Gabungan multi-<i>thresholding</i> tiga warna + morfologi + <i>filtering</i> kontur + <i>bitwise masking</i>	96,97%	93,75%	91,87%	0.011	8 menit 44 detik

Berdasarkan hasil *ablation study* pada Tabel 3, disajikan nilai kontribusi setiap tahapan segmentasi terhadap performa klasifikasi SVM. Pada konfigurasi awal yang hanya menggunakan gabungan multi-*thresholding* tiga warna dan *bitwise masking*, model mencapai akurasi latih 97,06% dan akurasi uji 91,87%, dengan rata-rata akurasi *5-fold cross validation* sebesar 91,25% dan standar deviasi sebesar 1,10%. Penambahan operasi morfologi meningkatkan konsistensi hasil segmentasi, yang tercermin pada kenaikan akurasi uji menjadi 92,63% dengan rata-rata akurasi *5-fold cross validation* sebesar 91,37% dan standar deviasi sebesar 1,40% dengan waktu komputasi 5 menit 56 detik. Selanjutnya, ketika ditambahkan tahapan *filtering* kontur, *pipeline* menghasilkan akurasi uji tertinggi sebesar 93,75% dengan stabilitas *cross validation* yang juga lebih baik, yaitu sebesar 91,87% dan standar deviasi sebesar 1,11%. Hal ini menunjukkan bahwa *filtering* kontur berperan penting dalam mengeliminasi area non-relevan, sehingga fitur yang diekstraksi lebih representatif terhadap objek daun. Dari sisi efisiensi, meskipun terdapat variasi waktu komputasi antar konfigurasi, peningkatan performa yang diperoleh, khususnya pada akurasi uji, menegaskan bahwa segmentasi berlapis diperlukan untuk mencapai

generalisasi yang lebih baik pada data uji. Dengan demikian, *pipeline* lengkap terbukti paling optimal dalam menyeimbangkan akurasi dan stabilitas dibandingkan konfigurasi parsial.

IV. SIMPULAN

Penelitian ini menunjukkan bahwa penerapan segmentasi berlapis dengan menggunakan kombinasi *preprocessing* yang mencakup *resizing*, peningkatan *brightness*, *Gaussian blur*, dan segmentasi berbasis warna HSV, morfologi, *filtering* kontur, dan *bitwise masking* mampu meningkatkan konsistensi fitur warna dan tekstur, sehingga mendukung performa model SVM dengan kernel RBF dalam mengklasifikasikan empat kategori kondisi daun tomat. Model yang diusulkan mencapai akurasi sebesar 96,97% pada data latih dan 93,75% pada data uji, dengan nilai validasi silang rata-rata $91,87\% \pm 0,011$. Hasil ablation study juga menegaskan bahwa setiap tahapan segmentasi memberikan kontribusi positif terhadap peningkatan akurasi uji. Temuan ini mengindikasikan bahwa *pipeline* lengkap memberikan keseimbangan terbaik antara performa klasifikasi dan konsistensi generalisasi. Namun, penelitian ini memiliki keterbatasan, antara lain penggunaan ambang HSV manual yang masih sensitif terhadap variasi pencahayaan, serta risiko artefak akibat proses *resize*. Untuk penelitian selanjutnya, dapat dipertimbangkan penerapan penyesuaian ambang warna secara adaptif, *augmentasi* pencahayaan maupun latar belakang, serta perbandingan dengan arsitektur CNN ringan seperti *MobileNet* sebagai pembanding eksternal.

DAFTAR PUSTAKA

- [1] A. Das, F. Pathan, J. R. Jim, M. M. Kabir, and M. F. Mridha, "Deep learning-based classification, detection, and segmentation of tomato leaf diseases: A state-of-the-art review," *Artificial Intelligence in Agriculture*, vol. 15, no. 2, pp. 192–220, Jun. 2025, doi: 10.1016/j.aiaa.2025.02.006.
- [2] D. Kurniawan, B. Tripama, and W. Widiarti, "Respon Pertumbuhan Dan Produksi Tanaman Tomat (*Lycopersicon esculentum*, Mill.) Terhadap Pemberian Pupuk Kandang Sapi Dan Pupuk NPK Pada Tanah Entisol," *National Multidisciplinary Sciences*, vol. 1, no. 2, pp. 250–261, Mar. 2022, doi: 10.32528/nms.v1i2.67.
- [3] M. J. Zebua, T. K. Suharsi, and M. Syukur, "Studi Karakter Fisik dan Fisiologi Buah dan Benih Tomat (*Solanum lycopersicum* L.) Tora IPB Physical Characteristic and Physiology of Tomato Fruit and Seed (*Solanum lycopersicum* L.) Tora IPB," 2019.
- [4] A. Lawi, N. S. Intizhami, R. Mukhtarom, and S. Amir, "Klasifikasi Penyakit Citra Daun Tanaman Tomat Dengan Ensemble Convolutional Neural Network," 2022, [Online]. Available: <https://www.kaggle.com/datasets/emmarex/plantdisease>.
- [5] Badan Pusat Statistik Indonesia, "Produksi Tanaman Sayuran, 2021-2023," *Badan Pusat Statistik*, Feb. 10, 2024. Accessed: Dec. 05, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/NjEjMg==/production-of-vegetables.html>
- [6] Z. Ikhsan, "Kenaikan Harga Tomat di Padang: Penyebab, Dampak, dan Solusi Alternatif," *Kumparan*, Padang, Jan. 23, 2024. Accessed: Feb. 07, 2025. [Online]. Available: https://kumparan.com/inspiration-room/kenaikan-harga-tomat-di-padang-penyebab-dampak-dan-solusi-alternatif-221RvE2177p/full?utm_source=chatgpt.com
- [7] Ditjen PSP, "Pengaruh Perubahan Iklim Terhadap Sektor Pertanian." Accessed: Feb. 07, 2025. [Online]. Available: <https://upland.psp.pertanian.go.id/public/artikel/1687919315/penaruh-perubahan-iklim-terhadap-sektor-pertanian#:~:text=Terjadinya%20perubahan%20iklim%20tersebut%20berdampak,dan%20perkembangan%20organisme%20pengganggu%20tanaman>.
- [8] M. Kabir, F. Unal, T. C. Akinci, A. A. Martinez-Morales, and S. Ekici, "Revealing GLCM Metric Variations across a Plant Disease Dataset: A Comprehensive Examination and Future Prospects for Enhanced Deep Learning Applications," *Electronics (Switzerland)*, vol. 13, no. 12, Jun. 2024, doi: 10.3390/electronics13122299.
- [9] M. M. F. Alim, "Identifikasi Penyakit Tanaman Tomat Menggunakan Algoritma Convolutional Neural Network dan Pendekatan Transfer Learning," Universitas Negeri Semarang, Semarang, 2020.
- [10] M. Niawati, F. Ardhy, T. H. Andika, P. Bintoro, U. A. Pringsewu, and J. A. Yani, "Aplikasi Diagnosis Penyakit pada Tumbuhan Tomat Berbasis Website," vol. 11, 2023.
- [11] J. Liu and X. Wang, "Tomato disease object detection method combining prior knowledge attention mechanism and multiscale features," *Front Plant Sci*, vol. 14, 2023, doi: 10.3389/fpls.2023.1255119.
- [12] A. Guerrero-Ibañez and A. Reyes-Muñoz, "Monitoring Tomato Leaf Disease through Convolutional Neural Networks," *Electronics (Switzerland)*, vol. 12, no. 1, Jan. 2023, doi: 10.3390/electronics12010229.
- [13] M. Khan, F. Gulan, M. Arshad, A. Zaman, and A. Riaz, "Early and late blight disease identification in tomato plants using a neural network-based model to augmenting agricultural productivity," *Sci Prog*, vol. 107, no. 3, Jul. 2024, doi: 10.1177/00368504241275371.
- [14] M. Faried, G. El Mirzaq, and R. Helilintar, "Sistem Pakar Diagnosa Penyakit Tanaman Tomat Menggunakan Metode Certainty Factor," Jul. 2021.
- [15] N. K. Majid, T. I. Noor, and R. Kurnia, "Faktor Faktor yang Mempengaruhi Produksi Usahatani Tomat," *Jurnal Ilmiah Mahasiswa AGROINFO GALUH*, vol. 9, Sep. 2022.
- [16] R. Soekarta, N. Nurdjan, and A. Syah, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)," vol. 8, no. 2, 2023.
- [17] A. Kadir and A. Susanto, *Teori dan Aplikasi Pengolahan Citra*. Yogyakarta: ANDI, 2013.
- [18] J. Ramos-Frutos *et al.*, "Digital Image Processing Applied in the Deformation Analysis of Hip Prosthesis: Multivariate Regression Analysis," *IEEE Access*, vol. 12, pp. 176938–176948, 2024, doi: 10.1109/ACCESS.2024.3506164.
- [19] T. Sutoyo, E. Mulyanto, V. Suhartono, O. D. Nurhayati, and Wijanarto, *Teori Pengolahan Citra Digital*. Yogyakarta: ANDI, 2009.
- [20] S. Talib, S. Sudin, and M. D. Suratin, "Penerapan Metode Support Vector Machine (Svm) pada Klasifikasi Jenis Cengkeh Berdasarkan Fitur Tekstur Daun," *Jurnal PROSISKO*, vol. 11, Mar. 2024.
- [21] H. Pratama, "Klasifikasi Tingkat Kematangan pada Citra Buah Sukun Berdasarkan Ekstraksi Fitur Warna dan Tekstur Dengan Metode LDA (Lineardisc Riminant Analysis)," Universitas Medan Area, Medan, 2024.

- [22] M. Ghudafa, T. Akbar, and H. Leidiyana, "Klasifikasi pada Citra Bunga dengan Ekstraksi Fitur Color Histogram," *Jurnal Ilmiah Teknik Informatika*, vol. 12, 2023.
- [23] E. Puerwandono and I. Maulana, "Penerapan Algoritma Svm Untuk Klasifikasi Citra Daun Sirih," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 6, no. 2, Dec. 2023.
- [24] L. P. R. Noviana and I. N. B. S. Nugraha, "Perbandingan Klasifikasi Citra Daun Herbal Menggunakan Metode Logistic Regression dan Decision Tree Classifier Berdasarkan Fitur (Warna, GLCM, Bentuk)," *JITU: Journal Informatic Technology And Communication*, vol. 7, no. 2, pp. 126–133, Nov. 2023, doi: 10.36596/jitu.v7i2.1241.
- [25] J. Riyono, C. E. Pujiastuti, S. D. Puspa, Supriyadi, and F. N. R. Putri, "Enhancing Lung Disease Classification through K-Means Clustering, Chan-Vese Segmentation, and Canny Edge Detection on X-Ray Segmented Images," *Jurnal Online Informatika*, vol. 9, no. 1, pp. 89–99, Apr. 2024, doi: 10.15575/join.v9i1.1178.
- [26] F. Amalya and S. Harlena, "(2022) Klasifikasi Buah Berkhasiat Obat Dengan Algoritme Euclidean Distance Menggunakan Ekstraksi Ciri Bentuk dan Tekstur," *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, vol. 7, no. 2, pp. 67–73, May 2022.
- [27] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*, 4th ed. Pearson, 2018.
- [28] Sugeng and H. Praminiarto, "Detection of Drowsiness in Drivers Using Image Processing and Support Vector Machine (SVM) Classification," *Jurnal Online Informatika*, vol. 9, no. 2, pp. 238–248, Aug. 2024, doi: 10.15575/join.v9i2.1076.
- [29] B. Audina, M. Fatekurohman, D. A. Riski, J. Matematika, and U. Jember, "Peramalan Arus Kas dengan Pendekatan Time Series Menggunakan Support Vector Machine," *Indonesian Journal of Applied Statistics*, vol. 4, no. 1, pp. 35–43, May 2021.
- [30] A. Yu, Y. Xiong, Z. Lv, P. Wang, J. She, and L. Wei, "New Method for Tomato Disease Detection Based on Image Segmentation and Cycle-GAN Enhancement," *Sensors*, vol. 24, no. 20, Oct. 2024, doi: 10.3390/s24206692.