

## Support Vector Machine Dalam Klasifikasi Jenis Beras Berdasarkan Ciri Fisik, Tekstur, dan Visual

Luqman Nur Fauzi<sup>1\*</sup>, Andi Kurniawan Nugroho<sup>1</sup>, Sri Heranurweni<sup>1</sup>, Budiani Destyningtias<sup>1</sup>

<sup>1</sup> Teknik Elektro Fakultas Teknik Universitas Semarang; Jl. Soekarno Hatta, RT.7/RW.7, Tlogosari Kulon, Kec. Pedurungan, Kota Semarang, Jawa Tengah 50196

Received: 26-07-2025

Accepted: 25-09-2025

### Keywords:

Klasifikasi beras;  
Support Vector Machine;  
Analisis Tekstur;  
Ekstraksi Fitur;  
Metode Machine Learning

### Correspondent Email:

[lukmannf8c@gmail.com](mailto:lukmannf8c@gmail.com)

**Abstrak.** Klasifikasi beras penting untuk menjamin kualitas dan efisiensi sesuai dengan kebutuhan konsumen dan industri. Metode tradisional klasifikasi beras biasanya memakan waktu, subjektif, dan rentan terhadap kesalahan manusia. Mengatasi hal ini, penelitian ini merekomendasikan algoritma Support Vector Machine (SVM) untuk mengklasifikasikan lima jenis beras, yaitu Arborio, Basmati, Ipsala, Jasmine, dan Karacadag, berdasarkan gabungan fitur fisik, tekstur, dan visual yang diperoleh dari basis data terdiri dari 75.000 gambar butir beras. Langkah-langkah prapemrosesan yang digunakan meliputi segmentasi gambar, penskalaan ke 128×128 piksel, konversi ke skala abu-abu, dan normalisasi. Fitur yang diekstraksi meliputi panjang, lebar, luas, dan rasio aspek (fitur fisik); kontras, korelasi, energi, dan homogenitas dari Grey Level Co-occurrence Matrix (GLCM) (fitur tekstur); serta nilai RGB rata-rata, kecerahan, intensitas, dan saturasi (fitur visual). Fitur-fitur ini diterapkan dalam pelatihan dan pengujian model SVM dengan rasio pelatihan-pengujian 80:20. Ukuran evaluasi yang digunakan meliputi akurasi, presisi, recall, F1-score, dan ROC-AUC. Model SVM mencapai akurasi total 99.43%, menunjukkan kinerja dan stabilitas yang baik dalam membedakan varietas beras, terutama saat kombinasi fitur dioptimalkan. Hasil penelitian ini menegaskan pentingnya integrasi fitur secara keseluruhan dalam meningkatkan kinerja klasifikasi. Penelitian ini menawarkan solusi stabil untuk klasifikasi otomatis beras dan berkontribusi pada integrasi kecerdasan buatan dalam sektor pengolahan makanan dan pertanian.

**Abstract.** Rice classification is crucial to ensure quality and efficiency that aligns with consumer and industry needs. Traditional rice classification methods are generally time-consuming, subjective, and prone to human error. To address this, this study recommends the Support Vector Machine (SVM) algorithm for classifying five types of rice—Arborio, Basmati, Ipsala, Jasmine, and Karacadag—based on a combination of physical, texture, and visual features obtained from a database comprising 75,000 rice grain images. The preprocessing steps used include image segmentation, scaling to 128×128 pixels, conversion to grayscale, and normalization. The extracted features include length, width, area, and aspect ratio (physical features); contrast, correlation, energy, and homogeneity from the Grey Level Co-occurrence Matrix (GLCM) (texture features); and average RGB values, brightness, intensity, and saturation (visual features). These features were applied in training and testing the SVM model with an 80:20 training-testing ratio. The evaluation metrics used include accuracy, precision, recall, F1-score, and ROC-AUC. The SVM model achieved a total accuracy of 99.43%, demonstrating good performance and stability in distinguishing rice varieties, especially when the feature combination was optimized. The results of this

*study emphasize the importance of integrating features as a whole to improve classification performance. This study offers a stable solution for automatic rice classification and contributes to the integration of artificial intelligence in the food processing and agriculture sectors.*

---

## 1. PENDAHULUAN

Beras merupakan tanaman pangan pokok yang sangat penting, memainkan peran sentral dalam gizi manusia dan sistem pertanian. Secara global, beras mencakup dua spesies utama yang dibudidayakan (*Oryza sativa* dan *Oryza glaberrima*) serta lebih dari 20 kerabat liar yang menyediakan keragaman genetik yang penting [1][2][3]. Dalam distribusi dan perdagangan, klasifikasi jenis beras merupakan aspek yang sangat penting karena berdampak pada kualitas, harga, dan standar industri. Namun, proses klasifikasi berdasarkan pengamatan visual terhadap karakteristik fisik, tekstur, dan ciri-ciri visual cenderung subjektif, memakan waktu, dan tidak konsisten [4][5][6]. Seiring dengan perkembangan teknologi, pemrosesan citra digital dan pembelajaran mesin menawarkan pendekatan alternatif yang efisien dan akurat. Salah satu metode yang banyak digunakan adalah *Support Vector Machine* (SVM), yang telah terbukti efektif dalam menangani masalah klasifikasi berbasis fitur berdimensi tinggi. Seiring dengan perkembangan teknologi, pemrosesan citra digital dan pembelajaran mesin menawarkan pendekatan alternatif yang efisien dan akurat. Salah satu metode yang banyak digunakan adalah SVM, yang telah terbukti efektif dalam menangani masalah klasifikasi berbasis fitur berdimensi tinggi [7],[8].

Berdasarkan keberhasilan metode SVM pada penelitian sebelumnya, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi jenis beras secara otomatis dengan memanfaatkan fitur fisik, tekstur, dan visual dari citra beras. Permasalahan yang diangkat adalah keterbatasan proses klasifikasi manual yang masih mengandalkan pengamatan manusia sehingga bersifat subjektif, memakan waktu, dan rentan terhadap ketidakkonsistenan antar penilai. Selain itu, banyak metode sebelumnya yang belum mengoptimalkan kombinasi berbagai jenis fitur. Penelitian ini menggunakan gambar dari lima jenis beras: Arborio, Basmati, Ipsala, Jasmine, dan Karacadag.

Tujuan utama dari penelitian ini adalah untuk mengidentifikasi dan mengekstrak fitur-fitur penting dari citra gabah padi, menerapkan metode SVM dalam mengembangkan model klasifikasi berdasarkan fitur-fitur tersebut, dan mengevaluasi kinerja model dibandingkan dengan algoritma klasifikasi lainnya. Penelitian ini bertujuan untuk menciptakan sistem klasifikasi jenis beras yang cepat, akurat, dan dapat diandalkan, sehingga memberikan kontribusi yang berarti bagi kemajuan aplikasi kecerdasan buatan di bidang pertanian dan industri makanan. Penelitian ini mengusulkan pendekatan integrasi fitur baru yang menggabungkan fitur fisik, tekstur, dan visual, sebuah pendekatan yang belum sepenuhnya dieksplorasi dalam penelitian klasifikasi beras sebelumnya yang menggunakan SVM.

## 2. TINJAUAN PUSTAKA

Bab ini menyajikan kajian pustaka terkait penelitian-penelitian terdahulu dalam bidang klasifikasi beras menggunakan *machine learning*. Pembahasan menacakup penggunaan berbagai jenis fitur citra seperti fitur fisik, tekstur, dan visual, serta algoritma klasifikasi yang umum digunakan seperti SVM, KNN, DT, dan metode lainnya yang menjadi dasar dalam merancang pendekatan yang lebih terintegrasi dan akurat dalam penelitian

### 2.1. Klasifikasi Beras Berbasis Fitur Fisik

Penelitian sebelumnya telah menunjukkan keefektifan SVM dalam klasifikasi padi, terutama berdasarkan fitur morfologi seperti panjang dan lebar. Meskipun efisien pada saat itu, pendekatan ini mengabaikan fitur tekstur dan visual yang dapat meningkatkan stabilitas klasifikasi [9]. Sebagai contoh, sebuah penelitian mencapai akurasi 96% dengan menggunakan fitur berbasis bentuk yang diekstraksi melalui MATLAB, namun hanya berfokus pada 10 fitur Random Forest yang paling penting [10]. Penelitian yang menyoroiti pentingnya pemilihan fitur [15] menunjukkan bahwa fitur fisik dapat memberikan hasil dengan akurasi tinggi dengan

menggunakan KNN dan *Decision Tree*, meskipun algoritma ini terbatas untuk dataset yang kompleks.

## 2.2. Integrasi Fitur Tekstur dan Visual

Aplikasi *machine learning* lainnya telah menggabungkan *Convolutional Neural Networks* (CNN) dan SVM untuk klasifikasi penyakit tanaman pada tomat menggunakan warna daun dan pola tekstur, yang menunjukkan kekuatan SVM dalam menangani fitur yang heterogen [11]. Selain itu, metode Local Binary Pattern (LBP) telah digunakan untuk analisis tekstur dalam klasifikasi ikan [12]. Pada saat yang sama, teknik *Grey Level Co-occurrence Matrix* (GLCM) digunakan untuk menangkap fitur tekstur dalam klasifikasi kematangan buah jeruk [13] dan kematangan buah kopi [14] menggunakan SVM, dimana kinerjanya melampaui metode *backpropagation*, meskipun hanya berdasarkan fitur warna. Metode pengolahan citra berbasis visual juga terbukti akurat, tetapi sebagian besar penelitian belum menggabungkan fitur fisik, tekstur, dan visual secara terpadu.

## 2.3. Perbandingan Algoritma Klasifikasi

Sebuah penelitian lanjutan membandingkan beberapa algoritma dan menemukan bahwa Random Forest menghasilkan akurasi tertinggi (96%) sementara SVM tetap memiliki kinerja yang stabil dan konsisten di berbagai metrik evaluasi. Sementara itu, ANN yang diuji pada penelitian Sebelumnya [16] memberikan akurasi yang tinggi (95%). Namun, ANN membutuhkan konfigurasi dan sumber daya komputasi yang lebih kompleks dibandingkan dengan SVM, yang relatif lebih mudah dan lebih efisien. Beberapa penelitian klasifikasi beras telah mengeksplorasi beragam teknik. Sebagai contoh, salah satu penelitian menggunakan fitur *Improved Local Ternary Pattern* (ILTP) yang dikombinasikan dengan *Binary Particle Swarm Optimization* (BPSO) dan SVM, yang mencapai akurasi 95% sekaligus mengurangi dimensi fitur [17][18], Namun, pendekatan ini hanya berfokus pada analisis tekstur tanpa memasukkan fitur warna atau bentuk, tidak seperti penelitian ini, yang mengintegrasikan atribut fisik, tekstur, dan visual untuk diskriminasi yang lebih baik. Penelitian lain

menerapkan segmentasi daerah aliran sungai, fitur warna, dan analisis tekstur LBP untuk mengklasifikasikan sampel beras ke dalam enam kategori kualitas, mencapai 96% segmentasi dan 88% akurasi klasifikasi [19]. Namun, metode ini berfokus pada penilaian kualitas campuran, tidak membedakan antara varietas beras, yang dibahas secara eksplisit dalam penelitian ini.

## 2.4. Penggunaan Data Spektral dan Sistem Hibrida

Pendekatan penginderaan spektral yang menggabungkan *near-infrared* (NIR) dengan *Partial Least Squares-Discriminant Analysis* (PLS-DA) dan SVM, mencapai 97% akurasi pencocokan untuk membedakan jenis tepung beras (*Indica* vs. *Japonica*) [20][21]. Meskipun efektif untuk data spektral, metode ini tidak dapat digunakan untuk klasifikasi berbasis citra dari seluruh butir beras, seperti dalam penelitian yang dilakukan ini. Selain itu, model hibrida *Deep Convolutional Neural Network* (DCNN)-SVM dikembangkan untuk mengklasifikasikan kelas penggilingan beras (Premium, Kelas 1-5) menggunakan fitur fisik seperti biji-bijian yang rusak dan berubah warna, dengan tingkat akurasi lebih dari 98% [22]. Berbeda dengan pendekatan yang berfokus pada penilaian menggunakan akuisisi *Raspberry Pi*, penelitian kami menargetkan klasifikasi jenis di seluruh varietas menggunakan kombinasi fitur fisik, tekstur, dan visual. Di Vietnam, pemrosesan gambar digunakan untuk mengekstrak fitur warna, morfologi, dan tekstur GLCM dari tujuh belas varietas padi, menggunakan kombinasi BPSO dan SVM untuk mengurangi jumlah fitur dari 248 menjadi 96, sekaligus meningkatkan akurasi hingga hampir 94% [23]. Namun, sebagian besar pendekatan tersebut membutuhkan perangkat keras khusus atau pemilihan fitur yang kompleks. Penelitian lain mengembangkan sistem penginderaan spektral portabel menggunakan SVM untuk identifikasi jenis beras secara real-time, dengan akurasi 98,41% [25]. Berbeda dengan metode berbasis spektral yang intensif perangkat keras tersebut, penelitian kali ini berfokus pada klasifikasi berbasis gambar yang dapat diakses melalui platform seperti *Google Collab*.

### 2.5. Pendekatan Alternatif dan Relevansi Studi Lain

Analisis komparatif mengungkapkan bahwa Jaringan Syaraf Tiruan (JST) mengungguli SVM multikelas dalam mengklasifikasikan beras Ponni, Basmati, dan Beras Merah, dengan tingkat akurasi 93,34% [24]. Meskipun menyoroti potensi pembelajaran mendalam, pendekatan ini mendukung model yang lebih sederhana dan dapat diinterpretasikan dengan menggabungkan jenis fitur dasar dengan SVM. Penelitian lain menggunakan SVM multikelas untuk mengklasifikasikan varietas beras Basmati, Ponni, dan Beras Merah berdasarkan deskriptor bentuk dan atribut warna, dengan akurasi 92,22% [26]. Sebaliknya, kumpulan fitur dalam penelitian kali ini yang diperoleh mencakup pengukuran tekstur dan morfologi, yang menangkap detail yang lebih kaya.

Sebuah penelitian menggabungkan metode deteksi tepi (Canny, Sobel, Prewitt) dengan fitur tekstur (Gabor, GLCM, LBP) untuk klasifikasi varietas padi ke dalam lima kategori, mencapai akurasi 96% dengan menggunakan SVM [27],[28]. Pendekatan dengan menekankan pada pipeline yang terperinci untuk ekstraksi tepi dan tekstur, sedangkan metode dalam penelitian kali ini mengintegrasikan atribut fisik, visual, dan tekstur dalam satu langkah yang efisien. Penelitian yang telah dilakukan [29] menunjukkan efektivitas penerapan beberapa model *machine learning* termasuk SVM, KNN, dan DT dalam mengklasifikasikan gangguan kesehatan mental berdasarkan 17 fitur gejala. Studi tersebut menegaskan bahwa pemilihan algoritma klasifikasi yang tepat sangat penting untuk menghasilkan performa prediksi yang optimal. Berbeda dengan pendekatan berbasis data tabular tersebut, penelitian ini menerapkan teknik serupa pada domain yang berbeda, yaitu klasifikasi citra digital varietas beras, dengan menekankan pada integrasi fitur fisik, tekstur, dan visual untuk meningkatkan akurasi dan generalisasi model.

### 2.6. Gap Penelitian dan Kontribusi

Mayoritas studi terdahulu hanya mengandalkan satu atau dua jenis fitur (misalnya hanya fisik atau tekstur), atau bergantung pada metode kompleks yang

membutuhkan perangkat keras khusus. Penelitian ini mengusulkan pendekatan integrasi fitur baru yang menggabungkan fitur fisik, tekstur, dan visual dari citra beras untuk meningkatkan akurasi dan generalisasi model klasifikasi.

Pendekatan ini dirancang agar dapat dijalankan pada lingkungan komputasi terbuka seperti Google Colab, tanpa memerlukan perangkat keras khusus atau optimasi berbasis metaheuristik yang kompleks.

## 3. METODE PENELITIAN

Bab ini menjelaskan tahapan metode yang digunakan dalam penelitian, mulai dari pengumpulan data citra beras, proses *preprocessing*, ekstraksi fitur, hingga tahap klasifikasi menggunakan SVM. Selain itu dijelaskan pula metode evaluasi performa model yang digunakan untuk menilai efektivitas pendekatan yang diusulkan.

### 3.1. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 75.000 citra gabah yang diperoleh dari situs web Kaggle. Dataset tersebut dibagi menjadi lima kelas: Arborio, Basmati, Ipsala, Jasmine, dan Karacadag, dengan masing-masing kelas terdiri dari 15.000 gambar. Dataset ini dibagi menjadi data latih dan data uji dengan rasio 80:20, di mana 80% atau 60.000 gambar digunakan untuk melatih model, dan 20% atau 15.000 gambar sisanya digunakan sebagai data uji.

### 3.2. Preprocessing Citra

Preprocessing citra bertujuan untuk menyederhanakan data visual tanpa kehilangan informasi penting. Prosesnya dimulai dengan mengubah gambar RGB menjadi *greyscale*, menghilangkan komponen warna yang tidak relevan untuk menganalisis tekstur dan morfologi beras. Citra *greyscale* kemudian dinormalisasi ke dalam 8 tingkat intensitas (0-7) untuk memudahkan pembangunan matriks GLCM untuk ekstraksi fitur tekstur. Selanjutnya, gambar diubah ukurannya menjadi 128×128 piksel untuk menstandarisasi dimensi dan meningkatkan efisiensi komputasi. Terakhir, segmentasi menggunakan *thresholding* diterapkan untuk memisahkan bulir beras dari latar belakang, memastikan ekstraksi fitur yang lebih akurat dan relevan.

### 3.3. Ekstraksi Fitur

Tahap penting berikutnya dalam analisis gambar adalah ekstraksi fitur. Penelitian ini menggunakan kombinasi fitur fisik, tekstur, dan visual. Tujuan dari ekstraksi fitur adalah untuk mendapatkan informasi numerik yang dapat digunakan dalam proses klasifikasi. Fitur-fitur tersebut digabungkan sebagai input ke dalam model klasifikasi SVM. Pada penelitian ini, ekstraksi fitur dikelompokkan menjadi tiga kategori utama yang diekstraksi dari citra beras, yaitu fitur fisik, tekstur, dan visual.

### 3.4. Klasifikasi Model Menggunakan SVM

Langkah klasifikasi menggunakan algoritma SVM untuk membedakan kelima varietas beras berdasarkan fitur fisik, tekstur, dan visual yang telah diekstraksi pada tahap sebelumnya. SVM adalah metode yang terkenal untuk menangani ruang fitur berdimensi tinggi dan menghasilkan batas klasifikasi yang tegas. Dalam penelitian ini, pengklasifikasi SVM dilengkapi dengan kernel *Radial Basis Function* (RBF) untuk menangkap hubungan non-linear dalam data dengan lebih baik. Parameter regularisasi diatur ke 1.0 (nilai default), dan estimasi probabilitas diaktifkan untuk memfasilitasi interpretasi probabilistik dan analisis kurva ROC. Konfigurasi ini dipilih setelah membandingkannya dengan kernel lain, yang menunjukkan bahwa kernel RBF memiliki akurasi yang sedikit lebih tinggi dan kinerja generalisasi yang lebih baik di seluruh dataset.

Model SVM pengujian untuk menentukan kemampuannya dalam mengklasifikasikan gambar gabah yang sebelumnya tidak menghasilkan terlihat prediksi kelas dengan dan benar, estimasi probabilitas untuk analisis kinerja lebih lanjut.

### 3.5. Metrik Evaluasi

Tujuan utama dari evaluasi model adalah untuk memastikan generalisasi yang kuat, bukan hanya kinerja yang baik pada data pelatihan. Hal ini membantu menentukan apakah suatu model cocok dibandingkan dengan model lainnya dengan menilai efektivitasnya dalam mengklasifikasikan data yang tidak terlihat. Metrik evaluasi utama meliputi akurasi, presisi, *recall*, *F1-score*, ROC AUC, dan *confusion matrix*. Masing-masing

memberikan wawasan tentang keandalan model dalam mengklasifikasikan jenis beras yang berbeda dalam berbagai kondisi. Berikut ini adalah rumus untuk menghitung evaluasi metrik.

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

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

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

dimana, TP adalah *true positive* (prediksi positif benar), TN adalah *true negative* (prediksi negatif benar), FP adalah *false positive* (prediksi positif salah), dan FN adalah *false negative* (prediksi negatif salah).


## 4. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari proses klasifikasi jenis beras menggunakan SVM berdasarkan fitur fisik, tekstur, dan visual yang telah diekstraksi. Evaluasi performa dilakukan menggunakan serangkaian metrik evaluasi dan *cross validation*. Selain itu, dilakukan pula pembahasan terhadap hasil yang diperoleh serta perbandingan kinerja dengan metode lain.

### 4.1. Preprocessing Citra

Sebelum proses klasifikasi, semua citra beras menjalani tahap *preprocessing* untuk memastikan keseragaman dan meningkatkan kinerja ekstraksi fitur. Tahap ini melibatkan beberapa langkah pemrosesan citra untuk mengurangi *noise*, menstandarisasi dimensi citra, dan mengisolasi daerah bulir padi untuk representasi fitur yang lebih baik. Gambar bulir beras dari dataset tersebut menjalani serangkaian langkah prapemrosesan standar, yang digambarkan pada Gambar 1 Proses berurutan dimulai dengan mengubah gambar menjadi *greyscale* karena pengurangan ini menjadi dimensi intensitas tunggal memungkinkan ekstraksi fitur tekstur dan *thresholding*. Gambar-gambar tersebut mengalami normalisasi menjadi delapan tingkat keabuan diskrit karena hal ini meningkatkan kontras sekaligus mengurangi *noise* untuk perhitungan fitur yang konsisten di semua sampel. Model ini menerima data spasial yang identik melalui standarisasi ukuran input menjadi 128×128 piksel untuk ekstraksi fitur

dan klasifikasi. Otsu *thresholding* memungkinkan segmentasi latar belakang yang akurat, sehingga memungkinkan ekstraksi detail morfologi dan tekstur dari butiran beras. Langkah-langkah pemrosesan ini meningkatkan konsistensi fitur sekaligus menghasilkan hasil klasifikasi yang lebih andal.



Gambar 1. Proses *Preprocessing* Citra

#### 4.2. Ekstraksi Fitur Fisik, Tekstur, Visual

Setelah proses *preprocessing* dilakukan, maka untuk merepresentasikan karakteristik geometris dari butiran beras, empat fitur fisik diekstraksi dari setiap gambar: panjang, lebar, luas, dan rasio aspek. Fitur-fitur ini dihitung berdasarkan kontur tersegmentasi dari setiap butir beras dan mencerminkan ukuran dan bentuk fisik beras. Seperti yang terlihat pada Tabel 1, varietas Ipsala dan Jasmine menunjukkan nilai panjang dan luas yang relatif lebih besar, sementara Basmati dan Arborio cenderung memiliki rasio aspek yang lebih rendah, yang mengindikasikan bentuk yang lebih bulat.

Tabel 1. Ekstraksi Fitur Fisik

Jenis Beras	P	L	Area	RA
Arborio (1)	69	36	1.916	1787
Arborio (2)	41	61	0.672	1689.5
Basmati (1)	36	92	0.391	1661
Basmati (2)	23	98	0.234	1741.5
Ipsala (1)	119	48	2.479	4201.5
Ipsala (2)	91	63	1.444	3469.5
Jasmine (1)	71	23	3.086	1275
Jasmine (2)	66	40	1.650	1225
Karacadag (1)	47	59	0.79	1828.5
Karacadag (2)	47	59	0.796	1889.5

Fitur tekstur diekstraksi menggunakan metode GLCM, yang menangkap hubungan spasial intensitas piksel. Fitur-fitur tersebut meliputi kontras (Kon), korelasi (Kore), energi (Eng), dan homogenitas (Hom) yang ditunjukkan pada Tabel 2.

Tabel 2. Ekstraksi Fitur Tekstur

Jenis Beras	Kon	Kore	Eng	Hom
Arborio (1)	0.078	0.990	0.880	0.986
Arborio (2)	0.148	0.979	0.885	0.981
Basmati (1)	0.336	0.956	0.882	0.974
Basmati (2)	0.364	0.956	0.876	0.972
Ipsala (1)	0.133	0.992	0.768	0.987
Ipsala (2)	0.201	0.987	0.791	0.983
Jasmine (1)	0.049	0.990	0.912	0.993
Jasmine (2)	0.095	0.981	0.914	0.987
Karacadag (1)	0.167	0.979	0.878	0.983
Karacadag (2)	0.169	0.978	0.874	0.982

Fitur visual diekstraksi dalam domain RGB, termasuk nilai rata-rata dan standar deviasi dari setiap saluran (Merah, Hijau, Biru). Fitur-fitur ini memberikan wawasan tentang komposisi warna dan variasi kecerahan di seluruh permukaan gabah. Tabel 3 dan Tabel 4 menunjukkan rata-rata dan variasi intensitas piksel per kelas.

Tabel 3. Ekstraksi Fitur Visual

Jenis Beras	Rerata R	Rerata G	Rerata B
Arborio (1)	0.063	0.992	0.885
Arborio (2)	0.100	0.985	0.891
Basmati (1)	0.197	0.974	0.890
Basmati (2)	0.214	0.974	0.885
Ipsala (1)	0.100	0.994	0.775
Ipsala (2)	0.141	0.991	0.800
Jasmine (1)	0.039	0.992	0.918
Jasmine (2)	0.077	0.985	0.920
Karacadag (1)	0.105	0.986	0.883
Karacadag (2)	0.101	0.987	0.879

Tabel 4. Standar Deviasi Persebaran Warna RGB

Jenis Beras	Std R	Std G	Std B
Arborio (1)	0.063	0.992	0.885
Arborio (2)	0.100	0.985	0.891
Basmati (1)	0.197	0.974	0.890
Basmati (2)	0.214	0.974	0.885
Ipsala (1)	0.100	0.994	0.775
Ipsala (2)	0.141	0.991	0.800
Jasmine (1)	0.039	0.992	0.918
Jasmine (2)	0.077	0.985	0.920
Karacadag (1)	0.105	0.986	0.883
Karacadag (2)	0.101	0.987	0.879

### 4.3. Evaluasi Kinerja SVM

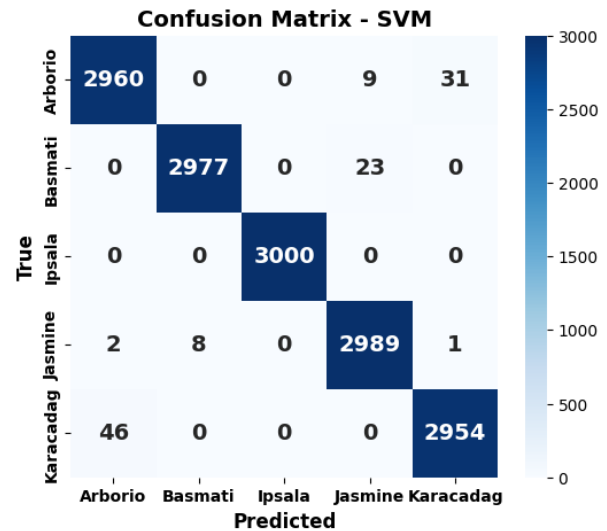
Evaluasi kinerja model merupakan langkah penting untuk menentukan seberapa efisien algoritma mengklasifikasikan data ke dalam kelompok-kelompok target. Dalam penelitian ini, evaluasi dilakukan menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score* yang secara komprehensif mampu menggambarkan kemampuan model untuk memprediksi kelas dengan benar, mengurangi klasifikasi yang salah, dan mempertahankan konsisten performa di semua kategori beras. Selain itu, ketahanan dan generalisasi model diuji menggunakan *5-fold-cross-validation*. Metode ini membantu menilai kemampuan generalisasi model dengan melatih dan memvalidasi model secara berulang-ulang pada berbagai partisi dataset, sehingga mengurangi risiko *overfitting*. Hasil evaluasi kinerja SVM dapat dilihat pada tabel 5.

Tabel 5. Evaluasi Kinerja SVM

Jenis Beras	Presisi	Recall	F1-Score	Support
Arborio	99.00	99.00	99.00	3000
Basmati	100.00	98.00	99.00	3000
Ipsala	100.00	100.00	100.00	3000
Jasmine	98.00	99.00	99.00	3000
Karacadag	99.00	99.00	99.00	3000
<b>M. Avg</b>	99.00	99.00	99.00	-
<b>W. Avg</b>	99.00	99.00	99.00	-
<b>Accuracy</b>	99.43			15000
<b>ROC AUC</b>	1.00			-

Performa klasifikasi dari model yang dirancang dievaluasi menggunakan berbagai metrik, termasuk presisi, *recall*, *F1-score*, akurasi, dan ROC AUC, seperti yang ditunjukkan pada Tabel 5 Model diuji pada 15.000 gambar, yang didistribusikan secara

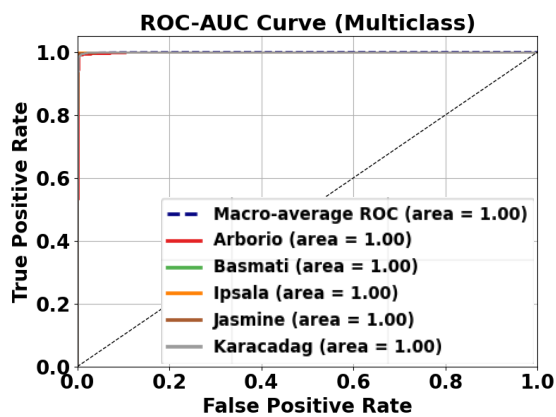
merata di lima varietas padi. Hasil evaluasi menunjukkan bahwa model mencapai akurasi **99.43%**, menunjukkan kemampuannya yang baik untuk mengklasifikasikan citra beras dengan benar di semua kelas. Nilai ROC-AUC juga mencapai 1.0, yang menunjukkan daya diskriminasi yang sangat baik dibandingkan dengan ambang batas keputusan yang bervariasi.



Gambar 2. Confusion Matrix Model SVM

Analisis *confusion matrix* pada Gambar 2 menggambarkan distribusi prediksi benar dan salah pada masing-masing kelas. Setiap baris mewakili kelas sebenarnya, sementara setiap kolom menunjukkan kelas yang diprediksi. Matriks ini menunjukkan bahwa sebagian besar citra diklasifikasikan secara tepat, terutama Ipsala yang mencatat 3000 prediksi akurat tanpa kesalahan.

Bersamaan dengan metrik klasifikasi dan *confusion matrix*, kinerja model diukur dengan menggunakan *Receiver Operating Characteristic - Area Under Curve* (ROC-AUC). Gambar 3 menggambarkan kurva ROC, yang dibuat menggunakan pengklasifikasi multikelas *One vs Rest* (OvR) untuk kelima kelas. Hasil output menunjukkan bahwa nilai ROC-AUC dari semua kelas adalah **1.00** yang mengimplikasikan pemisahan probabilitas yang sempurna di antara jenis-jenis beras.



Gambar 3. Kurva ROC-AUC Model SVM

#### 4.4. Analisis Performa Berdasarkan Fitur dan Metode

Evaluasi komparatif dilakukan untuk menyelidiki lebih lanjut efektivitas integrasi fitur yang diusulkan. Rangkaian percobaan pertama bertujuan untuk membandingkan kinerja pengklasifikasi SVM ketika diterapkan pada berbagai jenis kelompok fitur individu, termasuk fitur fisik, tekstur, dan visual, serta kombinasi terintegrasi dari ketiganya. Tabel 6 menunjukkan bahwa setiap satu fitur yang digunakan memiliki nilai yang lebih rendah dibandingkan dengan kombinasi dari ketiga fitur tersebut.

Tabel 6. Perbandingan Performa Berdasarkan Fitur

Fitur	Akurasi	Presisi	Recall	F1-Score
Fisik	96.99	97.00	96.99	96.00
Tekstur	84.08	85.31	84.08	84.08
Visual	92.18	92.13	92.18	92.13
Gabungan	99.43	99.43	99.43	99.43

Setelah membandingkan kinerja model berdasarkan jenis fitur secara individual, pada percobaan selanjutnya hasil klasifikasi yang diperoleh dengan menggunakan pendekatan integrasi fitur yang diusulkan dibandingkan dengan metode klasifikasi lainnya, seperti RF, KNN, dan DT, dengan menggunakan set fitur yang sama. Perbandingan dua tingkat ini memberikan gambaran yang lebih jelas tentang bagaimana fitur-fitur yang dipilih dan algoritma SVM berkontribusi terhadap kinerja keseluruhan.

Tabel 7 Perbandingan Metode SVM dengan Metode Lain

Metode	Akurasi	Presisi	Recall	F1-Score
SVM	99.43	99.43	99.43	99.43
RF	95.00	95.00	95.00	95.00
KNN	79.00	81.00	79.00	79.00
DT	88.00	88.00	88.00	88.00

#### 5. KESIMPULAN

- a. Penelitian ini berhasil membangun model klasifikasi jenis beras menggunakan fitur fisik, tekstur, dan visual dari 75000 citra yang mencakup lima varietas: Arborio, Basmati, Ipsala, Jasmine, dan Karacadag.
- b. Fitur yang digunakan meliputi statistik RGB, fitur tekstur berbasis GLCM, serta fisik seperti panjang, lebar, luas area, dan rasio aspek yang merepresentasikan karakteristik masing-masing varietas beras.
- c. Model SVM menunjukkan performa terbaik dengan akurasi **99.43%**, mengungguli metode klasifikasi lainnya seperti RF, KNN, dan DT.
- d. Keunggulan metode ini terletak pada kombinasi fitur yang heterogen, yang terbukti lebih efektif dibandingkan dengan penggunaan fitur tunggal, terutama dalam membedakan varietas beras yang secara visual dan struktural mirip.
- e. Kelemahan dari penelitian ini adalah belum diterapkannya sistem pengambilan gambar secara *real-time*, serta belum dilakukan optmasi fitur secara mendalam untuk efisiensi komputasi.
- f. Pengembangan selanjutnya dapat diarahkan pada integrasi dengan *deep learning*, sistem klasifikasi *real-time*, atau penggunaan metode seleksi dan optimasi fitur untuk meningkatkan efisiensi dan akurasi klasifikasi.

#### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

## DAFTAR PUSTAKA

- [1] K. H. Kaboré, A. I. Kassankogno, and D. Tharreau, "Brown spot of rice: Worldwide disease impact, phenotypic and genetic diversity of the causal pathogen *Bipolaris oryzae*, and management of the disease," *Plant Pathol.*, vol. 74, no. 4, pp. 908–922, 2025.
- [2] P. Panesar and S. Kaur, "Rice: Types and Composition," *Encycl. Food Heal.*, Dec. 2016, doi: 10.1016/B978-0-12-384947-2.00596-1.
- [3] S. E. M. Sedeek, T. M. Mazal, M. Osman, A. G. Hefeina, W. H. EL-Kallawy, and E. M. Bleih, "Genetic diversity among some rice genotypes under water shortage," *J. Plant Prod.*, vol. 13, no. 12, pp. 929–936, 2022.
- [4] V. A. A. Pellokila, K. Usman, and N. K. C. Pratiwi, "Pemanfaatan Convolutional Neural Network (CNN) Untuk Klasifikasi Jenis Beras Berbasis Citra," *eProceedings Eng.*, vol. 10, no. 5, 2023.
- [5] S. Ramadasan, M. Ramadasan, K. Vijayakumar, and G. Balaji, "Classification of Rice-Plant Images into Healthy/Disease Class using ResNetV2 Variants," in *2023 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES)*, IEEE, 2023, pp. 1–4.
- [6] L. Y. W. Lwin and A. N. Htwe, "Image classification for Rice leaf disease using AlexNet model," in *2023 IEEE Conference on Computer Applications (ICCA)*, IEEE, 2023, pp. 124–129.
- [7] M. Awad and R. Khanna, "Support Vector Machines for Classification," 2015, pp. 39–66. doi: 10.1007/978-1-4302-5990-9\_3.
- [8] A. Kurani, P. Doshi, A. Vakharia, and M. Shah, "A Comprehensive Comparative Study of Artificial Neural Network (ANN) and Support Vector Machines (SVM) on Stock Forecasting," *Ann. Data Sci.*, vol. 10, no. 1, pp. 183–208, 2023, doi: 10.1007/s40745-021-00344-x.
- [9] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man. Cybern.*, vol. SMC-3, no. 6, pp. 610–621, 1973, doi: 10.1109/TSMC.1973.4309314.
- [10] K. Gopalakrishnan and J. D. R. Vivek, "Rice grain classification using image processing technique," *Int. J. Health Sci. (Qassim)*, vol. 6, no. March, pp. 919–928, 2022, doi: 10.53730/ijhs.v6ns5.8779.
- [11] F. Felix, S. Faisal, T. F. M. Butarbutar, and P. Sirait, "Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun," *J. SIFO Mikroskil*, vol. 20, no. 2, pp. 117–134, 2019, doi: 10.55601/jsm.v20i2.670.
- [12] J. Arie, P. Ginting, R. M. Sari, M. Rafli, D. Siregar, and D. Kiswanto, "ANALISIS SUPPORT VECTOR MACHINE ( SVM ) UNTUK KLASIFIKASI JENIS KELAMIN PADA IKAN CUPANG DENGAN BANTUAN LOCAL BINARY PATTERN ( LBP )," vol. 8, no. 6, pp. 12782–12786, 2024.
- [13] M. Arief, "Klasifikasi Kematangan Buah Jeruk Berdasarkan Fitur Warna Menggunakan Metode SVM," *J. Ilmu Komput. dan Desain Komun. Vis.*, vol. 4, no. 1, pp. 9–16, 2019.
- [14] H. A. Sihombing and I. C. Bulolo, "Pengenalan Buah Kopi Berdasarkan Parameter Warna Menggunakan Algoritma Backpropagation Dan Algoritma Support Vector Machine (SVM)," *Seminastika*, vol. 3, no. 1, pp. 26–32, 2021, doi: 10.47002/seminastika.v3i1.234.
- [15] B. Arora, N. Bhagat, L. R. Saritha, and S. Arcot, "Rice Grain Classification using Image Processing & Machine Learning Techniques," in *2020 International Conference on Inventive Computation Technologies (ICICT)*, 2020, pp. 205–208. doi: 10.1109/ICICT48043.2020.9112418.
- [16] M. Koklu, I. Cinar, and Y. S. Taspinar, "Classification of rice varieties with deep learning methods," *Comput. Electron. Agric.*, vol. 187, p. 106285, 2021, doi: <https://doi.org/10.1016/j.compag.2021.106285>.
- [17] A. Haidar, M. Field, J. Sykes, M. Carolan, and L. Holloway, "PSPSO: A Package for Parameter Selection using Particle Swarm Optimization," *SoftwareX*, vol. 15, p. 100706, 2021.
- [18] T. T. K. Nga, T. Pham-Viet, D. M. Nhat, V. Y. Mariano, and T. Do-Hong, "Applying Texture Feature Based on Local Ternary Pattern for Binary Particle Swarm Optimization plus Support Vector Machine-based Classification of Rice Varieties," in *2022 IEEE Ninth International Conference on Communications and Electronics (ICCE)*, 2022, pp. 412–417. doi: 10.1109/ICCE55644.2022.9852044.
- [19] N. Nagoda and L. Ranathunga, "Rice Sample Segmentation and Classification Using Image Processing and Support Vector Machine," in *2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS)*, 2018, pp. 179–184. doi: 10.1109/ICIINFS.2018.8721312.

- [20] J. P. M. Andries and Y. Vander Heyden, "Improved Multi-Class Discrimination by Common-Subset-of-Independent-Variables Partial-Least-Squares Discriminant Analysis," *Talanta*, vol. 234, p. 122595, 2021.
- [21] P. S. Sampaio, A. Castanho, A. S. Almeida, J. Oliveira, and C. Brites, "Identification of rice flour types with near-infrared spectroscopy associated with PLS-DA and SVM methods," *Eur. Food Res. Technol.*, vol. 246, no. 3, pp. 527–537, 2020.
- [22] K. M. A. Bejerano, C. C. H. IV, and J. J. R. Balbin, "Rice (*Oryza Sativa*) Grading classification using Hybrid Model Deep Convolutional Neural Networks - Support Vector Machine Classifier," in *2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET)*, 2022, pp. 1–6. doi: 10.1109/IICAIET55139.2022.9936869.
- [23] T. T. K. Nga, T. V. Pham, D. M. Tam, I. Koo, V. Y. Mariano, and T. Do-Hong, "Combining binary particle swarm optimization with support vector machine for enhancing rice varieties classification accuracy," *IEEE Access*, vol. 9, pp. 66062–66078, 2021.
- [24] S. Ibrahim, S. B. A. Kamaruddin, A. Zabidi, and N. A. M. Ghani, "Contrastive analysis of rice grain classification techniques: multi-class support vector machine vs artificial neural network," *IAES Int. J. Artif. Intell.*, vol. 9, no. 4, p. 616, 2020.
- [25] Z. H. Kok, A. R. M. Shariff, M. S. M. Alfatni, and S. Khairunniza-Bejo, "Support Vector Machine in Precision Agriculture: A Review," *Comput. Electron. Agric.*, vol. 191, p. 106546, 2021.
- [26] S. Ibrahim, N. A. Zulkifli, N. Sabri, A. A. Shari, and M. R. M. Noordin, "Rice grain classification using multi-class support vector machine (SVM)," *IAES Int. J. Artif. Intell.*, vol. 8, no. 3, p. 215, 2019.
- [27] A. Albahry, M. Widiastuti, and S. Wahyuni, "Identifikasi Varietas Padi Menggunakan Pengolahan Citra Digital dan Analisis Diskriminan," *J. Penelit. Pertan. Tanam. Pangan*, vol. 34, p. 89, Nov. 2015, doi: 10.21082/jpntp.v34n2.2015.p89-96.
- [28] Y. Yuan, "Noise-aware Canny Algorithm for Edge Detection," in *2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT)*, IEEE, 2022, pp. 1107–1110.
- [29] T. Muthia, N. Nurrahma, and Y. E. Putra, "Perbandingan Akurasi Model Pembelajaran Mesin SVM, KNN, Decision Tree, dan Naive Bayes pada Klasifikasi Gangguan Kesehatan Mental," *Electr. J. Rekayasa dan Teknol. Elektro*, vol. 18, no. 3, pp. 363–368, 2024.