

Klasifikasi SVM Menggunakan Optimasi PSO Untuk Kelayakan Biji Kopi Dengan Level Medium Roast

SVM Classification Using PSO Optimization For Medium Roast Coffee Bean Eligibilityy

Wicaksono Agung Saputro¹, Pulung Nurtantio Andono², M Arief Soeleman³

Magister Teknik Informatika, Universitas Dian Nuswantoro

Received 25 April 2025; Revised 23 May 2025; Accepted 26 May 2025

E-mail: ¹w3.saputro@gmail.com, ²pulung@dsn.dinus.ac.id, ³m.rief.soeleman@dsn.dinus.ac.id

Abstrak - Biji kopi dengan medium roast memiliki ciri warna coklat muda kehitaman, permukaan sedikit berminyak, dan retakan biji yang tidak terlalu lebar. Karena kopi merupakan hasil bumi yang banyak dikonsumsi dengan tingkat kematangan medium, diperlukan quality control yang efektif untuk memastikan biji kopi layak konsumsi. Penelitian ini mengambil sampel dari perusahaan terkait dan menggunakan metode GLCM untuk ekstraksi fitur numerik dari biji kopi, serta SVM dengan kernel RBF untuk klasifikasi, mengingat pentingnya pemilihan kernel dan parameter dalam menentukan akurasi. Untuk meningkatkan akurasi, diterapkan optimasi menggunakan PSO. Hasil klasifikasi menggunakan SVM saja mencapai akurasi 85,37%, sedangkan dengan optimasi PSO, akurasi meningkat menjadi 93,57%, menunjukkan bahwa penerapan PSO pada algoritma SVM mampu meningkatkan performa klasifikasi biji kopi medium roast secara signifikan.

Kata kunci: SVM, PSO, Biji Kopi Medium Roast

Abstract - Medium roast coffee beans are characterized by a light brown to dark brown color, a slightly oily surface, and coffee bean cracks that are not too wide. Since coffee is a widely consumed agricultural product, especially at the medium roast level, effective quality control is necessary to ensure the beans are fit for consumption. This study collected samples from a related company and used the GLCM method for feature extraction to generate numerical data from the coffee beans, and SVM with an RBF kernel for classification, considering the importance of kernel and parameter selection in determining accuracy. To further improve accuracy, PSO optimization was applied. The classification results using SVM alone achieved an accuracy of 85.37%, while applying PSO optimization increased the accuracy to 93.57%, demonstrating that integrating PSO into the SVM algorithm significantly enhances the classification performance of medium roast coffee beans.

Keywords: SVM, PSO, Medium Roast Coffee Beans

1. PENDAHULUAN

Kopi merupakan minuman yang populer di Indonesia dan dikenal memiliki berbagai manfaat kesehatan, seperti kandungan antioksidan, peningkat kinerja otak, serta pencegah kanker. Tingginya permintaan terhadap kopi mendorong pertumbuhan pesat industri kopi di Indonesia. Sebelum dikonsumsi, biji kopi melalui beberapa tahapan proses, yaitu pemotongan, pengeringan, dan proses pemanggangan (roasting) yang terbagi menjadi tiga tingkat: Light, Medium, dan Dark Roast. Biji kopi medium roast yang berkualitas memiliki warna coklat kehitaman, pecahan kecil, dan mengeluarkan minyak. Sementara itu, Pengolahan Citra Digital adalah proses menggunakan komputer supaya memanipulasi gambar dua dimensi untuk merepresentasikan objek secara numerik melalui serangkaian operasi. Citra digital sendiri terdiri dari array angka yang terbentuk dari perpotongan baris (i) dan kolom (j), yang menghasilkan piksel [1]. Citra digital terdiri dari

dua jenis, yaitu Color Image dan Grayscale Image. Color Image umumnya menggunakan model RGB karena kontras warnanya lebih baik dibanding CMYK. Grayscale Image memiliki rentang warna 8-bit dari putih hingga hitam dan sering digunakan dalam aplikasi medis seperti USG dan radiologi [2].

Metode ekstraksi fitur *Gray Level Co-Occurrence Matrix* terbukti efektif dalam mendeteksi luas permukaan objek dengan menganalisis tingkat keabuan. Teknik ini mengevaluasi variasi warna dalam kisaran 1 hingga 255 dan menghitung frekuensi kemunculan pasangan piksel yang berdekatan berdasarkan jarak dan arah tertentu. GLCM mempertimbangkan empat arah utama, yaitu 0° , 45° , 90° , dan 135° , serta menghasilkan fitur-fitur seperti Dissimilarity, Correlation, Homogeneity, Contrast, dan Energy [3]. Algoritma *Support Vector Machine* menyelesaikan tugas klasifikasi dengan memanfaatkan hyperplane optimal yang memisahkan antar kelas, dan bergantung pada data pelatihan yang dikenal sebagai support vector. Awalnya, SVM dirancang sebagai pemisah linear, namun kemudian dikembangkan untuk mengatasi kasus non-linear melalui penggunaan kernel trick sehingga memungkinkan pemetaan data ke ruang dengan jumlah dimensi yang lebih tinggi [4]. *Particle Swarm Optimization* merupakan algoritma pencarian global yang terinspirasi dari perilaku kolektif hewan seperti burung dan ikan saat mencari makan. Algoritma ini memulai dengan penyebaran partikel secara acak, lalu secara bertahap memperbarui posisi partikel pada setiap generasi untuk menemukan solusi terbaik, baik berdasarkan pengalaman individu maupun posisi terbaik secara keseluruhan dalam ruang berdimensi tinggi [5].

Pada penelitian sebelumnya yang telah dilakukan oleh Edwin R. Arboleda et al yang membahas penerapan membahas tentang bagaimana mengklasifikasi secara otomatis pembusukan pada biji kopi. Penelitian ini berfokus pada bagaimana kondisi biji kopi yang mengalami pembusukan sehingga tidak layak untuk digunakan [1].

Pada penelitian selanjutnya telah dilakukan oleh Jessie R. Balbin et al yang membahas pada penyortiran secara otomatis pada biji kopi yang mengalami pembusukan dengan klasifikasi Convolutional Neural Network (CNN), penelitian ini berhasil memperoleh nilai akurasi tertinggi sebesar 98,7% [2].

Pada penelitian selanjutnya telah dilakukan oleh Joao Paulo Lebarck Pizzaia et al. yang membahas berfokus pada klasifikasi biji kopi arabika menggunakan Multilayer Perceptron Neural Network dengan pendekatan Back-Propagation Neural Network untuk pengambilan keputusan. Teknik image processing seperti K-Mean Shift, Blob, dan Canny Edge digunakan untuk mengekstraksi fitur dari biji kopi, bertujuan meningkatkan efisiensi dalam proses pengklasifikasian biji kopi [6].

Selanjutnya, penelitian oleh Bagus Prindo et al. yang menunjukkan bahwa ekstraksi fitur dan normalisasi data dapat meningkatkan kinerja model Machine Learning, khususnya SVM dengan kernel RBF. Normalisasi terbukti meningkatkan akurasi, dan partisi data pelatihan yang lebih besar menghasilkan model yang lebih akurat. Optimasi parameter menggunakan *Particle Swarm Optimization* (PSO) mampu meningkatkan akurasi sebesar 1–4%, dengan hasil terbaik berupa akurasi 97,86% pada SVM kernel RBF [7].

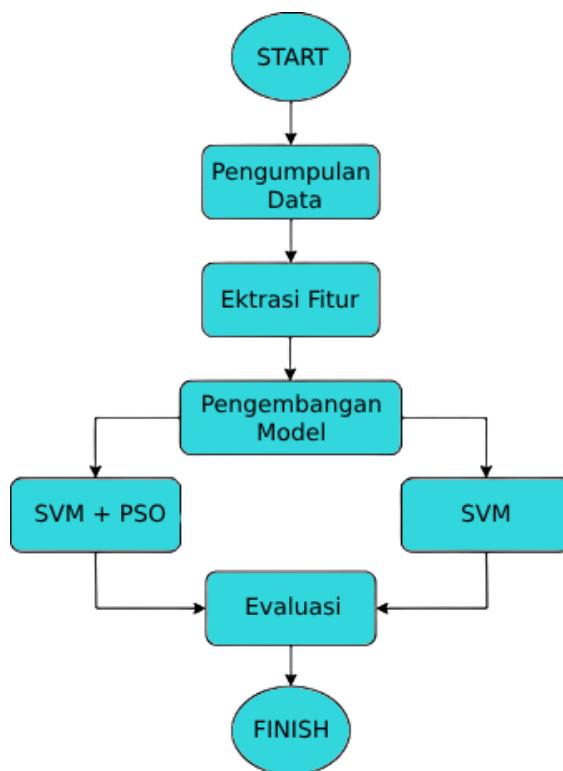
Namun, Algoritma SVM tidak selalu menghasilkan performa yang optimal, sehingga diperlukan metode optimasi untuk meningkatkan kinerjanya. Dalam penelitian ini, metode optimasi *Particle Swarm Optimization* (PSO) diterapkan untuk memperbaiki kinerja algoritma *Support Vector Machine* (SVM). Berdasarkan studi sebelumnya, PSO telah terbukti efektif dalam meningkatkan akurasi SVM. Sehingga pada tahap identifikasi fitur tekstur dari gambar kemudian dimasukkan ke dalam pengklasifikasi SVM dioptimalkan dengan algoritma PSO untuk mencapai tujuan mengidentifikasi image kerang batik layak dan tidak layak tersebut.

Penelitian ini berfokus pada perbedaan nilai akurasi tertinggi pada Algoritma SVM yang dioptimalkan dengan PSO. Algoritma SVM tidak selalu memberikan hasil optimal, sehingga diperlukan metode optimasi untuk meningkatkan kinerjanya. PSO terbukti efektif dalam meningkatkan akurasi SVM, yang diaplikasikan pada tahap identifikasi fitur tekstur gambar untuk mengklasifikasikan gambar biji kopi.

Tujuan penelitian ini adalah menerapkan teknik terbaik untuk mendeteksi kelayakan biji kopi dengan medium roast, mengurangi penurunan kualitas, serta meningkatkan produktivitas. Penggunaan machine learning dan optimasi parameter terbukti efektif dalam meningkatkan akurasi. Diharapkan, hasil penelitian ini dapat membantu industri kopi dalam meningkatkan kualitas dan hasil produksi, sekaligus mengurangi biaya pengobatan yang tinggi, untuk mencegah penurunan pendapatan perusahaan.

2. METODE PENELITIAN

Penelitian ini memusatkan perhatian pada penerapan optimasi *Support Vector Machine* (SVM) dengan menggunakan *Particle Swarm Optimization* (PSO) untuk mendeteksi kelayakan biji kopi medium roast. Metodologi penelitian dirancang secara menyeluruh dan sistematis guna memastikan proses identifikasi, analisis, serta evaluasi efektivitas dari teknik yang diusulkan berjalan optimal.



Gambar 1. Metode Penelitian

Berdasarkan Gambar 1. Metode Penelitian menggambarkan alur pengembangan model klasifikasi, dimulai dari pengumpulan data, ekstraksi fitur, hingga pengembangan model. Model dibangun melalui dua jalur, yaitu menggunakan SVM biasa dan SVM yang dioptimasi dengan PSO. Kedua model kemudian dievaluasi untuk membandingkan performanya sebelum proses berakhir.

2.1 Pengumpulan Data

Penelitian ini memanfaatkan data sekunder berupa gambar yang berasal dari sumber privat milik sebuah coffee shop. Dataset tersebut bersifat tertutup dan diperoleh melalui metode observasi, yakni dengan melakukan pengamatan langsung. Jumlah citra tersedia yang digunakan pada pengujian ini sebanyak 400 file citra.

Tabel 1 Komposisi Dataset Biji Kopi

Jenis data	Spesifikasi		Total
	Layak	Tidak Layak	
Data Training	140	140	280
Data Testing	60	60	120
Jumlah Data			400

Berdasarkan Tabel 1 menunjukkan komposisi dataset biji kopi yang digunakan dalam proses pelatihan dan pengujian model. Dataset ini terdiri dari dua kategori, yaitu "Layak" dan "Tidak Layak". Untuk data pelatihan (training), terdapat masing-masing 140 data "Layak" dan 140 data "Tidak Layak", sehingga total data training berjumlah 280. Sementara itu, untuk data pengujian (testing), masing-masing kategori juga memiliki 60 data, sehingga total data testing adalah 120. Secara keseluruhan, jumlah seluruh data dalam dataset mencapai 400. Penyusunan data yang seimbang antara kedua kategori ini bertujuan untuk memastikan bahwa model dapat belajar secara adil dan menghindari bias terhadap salah satu kelas.

Roasting adalah proses penting dalam pengolahan biji kopi yang menentukan cita rasa akhir. Terdapat tiga tingkat roasting yang umum digunakan: Light Roast, Medium Roast, dan Dark Roast. Di Indonesia, pelaku usaha kopi lebih memilih Medium Roast karena profil rasanya sesuai dengan selera konsumen lokal dan cocok untuk berbagai metode penyeduhan [2].



Gambar 2 Biji Kopi Medium Roast Kondisi Layak

Berdasarkan Gambar 2 menampilkan biji kopi yang memenuhi kriteria medium roast. Warna biji terlihat cokelat keemasan hingga cokelat tua, dengan permukaan yang mungkin sedikit berminyak. Biji kopi dengan karakteristik ini dianggap layak karena mencerminkan proses pemanggangan yang tepat dan memenuhi standar kualitas untuk diproses lebih lanjut.



Gambar 3 Biji Kopi Medium Roast Tidak Layak

Berdasarkan Gambar 3 menunjukkan biji kopi yang tidak sesuai dengan standar medium roast. Warna biji cenderung terlalu gelap, bahkan mendekati hitam, dengan permukaan yang tampak berminyak berlebihan. Kondisi ini menandakan proses pemanggangan yang berlebihan, sehingga biji kopi dianggap tidak layak ekspor karena menurunkan kualitas dan tidak sesuai dengan standar yang ditetapkan.

2.2 Pengolahan Citra digital

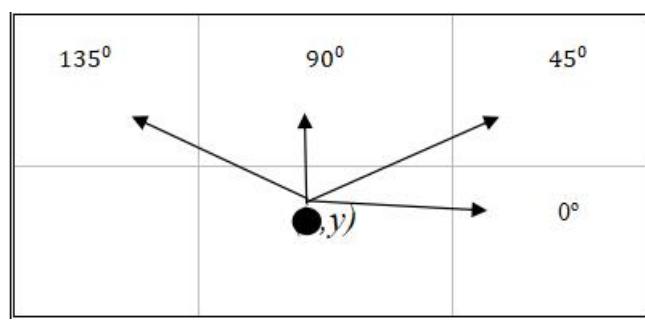
Pengolahan citra digital proses yang melibatkan manipulasi gambar sehingga direpresentasikan sebagai array angka, di mana setiap titik persilangan antara baris dan kolom membentuk piksel sebagai unit terkecil dalam citra. Setiap piksel mengandung dua informasi utama: Digital Number (DN) dan Brightness Value (BV). Nilai DN bervariasi tergantung pada kedalaman bit citra, misalnya 0–1063 untuk citra 10 bit, 0–255 untuk citra 8 bit, dan 0–63 untuk citra 6 bit, yang menunjukkan rentang warna yang dimiliki oleh piksel. Nilai BV mencerminkan tingkat kecerahan atau intensitas warna dari piksel tersebut.

Pengolahan citra digital memungkinkan pengambilan informasi penting seperti pola, tekstur, dan fitur lainnya yang berguna dalam berbagai aplikasi, termasuk klasifikasi, segmentasi, dan analisis visual. Salah satu metode yang banyak sehingga dimanfaatkan dalam analisis tekstur adalah *Gray-Level Co-occurrence Matrix* (GLCM), yang mengevaluasi distribusi intensitas warna dalam citra untuk mengidentifikasi pola tekstur tertentu [8].

2.3 Ekstraksi Fitur

Metode pengambilan fitur menggunakan metode GLCM (*Gray Level Co-occurrence Matrix*) dilakukan dengan membentuk matriks co-occurrence yang merepresentasikan hubungan antara pasangan piksel berdasarkan jarak dan arah tertentu [9]. Matriks ini menghitung kemungkinan kemunculan dua piksel dengan nilai intensitas tertentu yang terletak pada jarak (d) dan sudut (θ) tertentu. Arah umumnya ditentukan oleh empat sudut yaitu 0° , 45° , 90° , dan 135° . GLCM menghasilkan berbagai fitur penting seperti Dissimilarity, Correlation, Homogeneity, Contrast, dan Energy [3].

Biasanya, jarak antar piksel diatur sebesar satu piksel [10]. Matriks co-occurrence berbentuk persegi, dengan jumlah elemen yang setara dengan kuadrat dari jumlah tingkat intensitas piksel dalam citra. Setiap elemen pada koordinat (p, q) dari matriks ini menunjukkan probabilitas bahwa piksel dengan nilai p berada di dekat piksel dengan nilai q dalam arah tertentu (θ hingga 180°).



Gambar 4 Array Hubungan Ketetanggaan pada GLCM

Berdasarkan Gambar 4 menunjukkan hubungan ketetanggaan pada GLCM, di mana arah ketetanggaan diatur pada sudut 0° , 45° , 90° , dan 135° . Pola hubungan ketetanggaan ini digunakan dalam pembentukan GLCM untuk menganalisis tekstur citra berdasarkan intensitas keabuan piksel yang berdekatan dalam arah tertentu.

Dalam penelitian ini, fitur yang digunakan mencakup Homogeneity, Contrast, Correlation, dan Energy. Rumus-rumus yang digunakan dipilih karena masing-masing fitur memiliki karakteristik yang relevan dengan kebutuhan penelitian.

1) Energy

Energy menggambarkan tingkat keseragaman dalam sebuah citra. Jika intensitas piksel pada citra cukup merata atau homogen, maka nilai energy-nya akan tinggi. Nilai ini menunjukkan konsistensi distribusi intensitas dalam citra [10].

2) Homogeneity

Homogeneity menunjukkan tingkat kemiripan nilai intensitas piksel dalam suatu citra. Semakin kecil variasi intensitas lokalnya, semakin tinggi nilai homogeneity-nya. Nilai ini dihitung berdasarkan perubahan tekstur lokal dalam citra [10].

3) Contrast

Contrast merepresentasikan tingkat perbedaan intensitas antar piksel di suatu area citra. Nilai ini mengindikasikan seberapa tersebar intensitas piksel dalam citra, dan mencerminkan ketajaman serta kedalaman bayangan pada gambar [10].

4) Correlation

Correlation mengukur hubungan antara intensitas piksel yang berdekatan, serta keteraturan tekstur citra. Nilai korelasi rendah menunjukkan keseragaman intensitas, sedangkan nilai tinggi mengindikasikan distribusi intensitas yang bervariasi [10].

2.4 SVM (*Support Vector Machine*)

Algoritma *Support Vector Machine* (SVM) memecahkan masalah klasifikasi pada membangun hyperplane terbaik yang memisahkan antar kelas. Hyperplane ini ditentukan berdasarkan titik-titik data pelatihan yang berada paling dekat dengan batas pemisah, yang disebut *support vector* [4]. Semakin besar margin atau jarak antara hyperplane dan support vector dari masing-masing kelas, semakin baik kemampuan generalisasi model. SVM bertujuan mencari hyperplane terbaik yang dapat membedakan dua kelompok data dalam ruang fitur, di mana margin tersebut menunjukkan jarak minimum antara hyperplane dengan data point terdekat dari masing-masing kelompok data.

Jika data dalam ruang input tidak dapat dipisahkan secara linier, maka pendekatan SVM dengan soft margin mungkin gagal dalam menemukan hyperplane yang optimal untuk memisahkan kelas, sehingga tidak mampu meminimalkan kesalahan klasifikasi maupun melakukan generalisasi secara efektif. Untuk mengatasi hal ini, digunakan fungsi kernel dapat memungkinkan transformasi data ke dalam ruang berdimensi di atas rata-rata, yang disebut ruang kernel, di mana data tersebut dapat dipisahkan secara linier [11].

1) *Radial Basis Function* (RBF) Kernel

Kernel RBF memiliki dua parameter utama, yaitu Cost dan Gamma. Parameter gamma menentukan sejauh mana pengaruh suatu data pelatihan terhadap data lainnya; nilai gamma yang kecil mencerminkan pengaruh yang lebih luas, sedangkan gamma yang besar hanya memengaruhi area di sekitar titik data tersebut. Jika gamma rendah, titik-titik data yang jauh dari margin masih diperhitungkan dalam menentukan batas keputusan. Sebaliknya, gamma tinggi akan memfokuskan perhatian hanya pada titik-titik yang dekat dengan margin [7].

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (8)$$

2.5 PSO (*Particle Swarm Optimization*)

Particle Swarm Optimization (PSO) adalah algoritma pencarian global didasarkan pada tingkah laku hewan seperti ikan serta burung saat mencari makan. PSO memulai dengan penyebaran partikel secara acak, lalu memperbarui posisinya di setiap generasi berdasarkan pengalaman individu dan posisi terbaik secara global untuk menemukan solusi optimal dalam ruang multidimensi [5].

2.6 Confusion Matrix

Menilai efisiensi dari sebuah sistem klasifikasi sangatlah penting karena hal ini mencerminkan tingkat efektivitas dan akurasi sistem dalam melakukan klasifikasi data [12].

Tabel 2 Confusion Matrix

	Aktual: Negatif	Aktual: Positif
Prediksi: Negatif	TN	FN
Prediksi: Positif	FP	TP

Berdasarkan Tabel 2, *True Negative* (TN) merepresentasikan jumlah prediksi negatif yang sesuai dengan kondisi sebenarnya, sedangkan *True Positive* (TP) menunjukkan jumlah prediksi positif yang benar. Dua jenis kesalahan yang umum terjadi adalah *False Negative* (FN), yaitu ketika model memprediksi negatif padahal sebenarnya positif, dan *False Positive* (FP), yaitu ketika model memprediksi positif namun kenyataannya negatif.

- 1) Akurasi menunjukkan seberapa tepat model dalam mengklasifikasikan data secara keseluruhan. Rumus akurasi dihitung sebagai berikut:

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

- 2) Recall mengukur kemampuan model dalam menemukan seluruh data relevan atau benar dari suatu kelas. Recall dihitung dengan rumus berikut:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (10)$$

- 3) Presisi menggambarkan sejauh mana prediksi positif yang dihasilkan oleh model benar-benar akurat. Nilai presisi dihitung menggunakan rumus berikut:

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (11)$$

3. HASIL DAN PEMBAHASAN

3.1. Ekstrasi Fitur GLCM

Citra yang telah melewati tahap pra-pemrosesan selanjutnya akan diekstraksi menggunakan metode GLCM, dengan fitur-fitur seperti contrast, homogeneity, correlation dan energy. Proses ini akan menghasilkan nilai numerik dari berbagai sudut orientasi, yaitu 0°, 45°, 90°, dan 135°, sebagaimana ditunjukkan berikut ini.

- 1) Hasil Ekstrasi Fitur Sudut 0°

Tabel 3 Ekstrasi fitur pada sudut 0°

No	Nama Image	Contrast	Homogeneity	Correlation	Energy	Kelas
1.	Image1	0,881006853	0,111144677	959,0785604	0,016156451	Layak
2.	Image2	0,909730083	0,162814423	794,7949505	0,04281235	Layak
3.	Image3	0,8771309	0,120484686	1080,340233	0,020716426	Layak
4.	Image4	0,919765486	0,154620691	844,1712852	0,025259661	Layak
5.	Image5	0,869049679	0,129111625	1241,659642	0,020284883	Layak

...
400	Image400	0,891542428	0,192705446	1209,579381	0,055763748	Tidak Layak

Berdasarkan Tabel 3 menyajikan hasil ekstraksi fitur pada sudut 0° , yang mencakup lima jenis fitur GLCM: Contrast, Homogeneity, Correlation dan Energy. Adapun rentang nilai dari masing-masing fitur yang ditampilkan dalam tabel tersebut adalah sebagai berikut: Contrast dari 612,9036823 sampai 1833,504094, Homogeneity dari 0,087990126 sampai 0,361740782, Correlation dari 0,790572325 sampai 0,945366402 dan Energy dari 0,014113029 sampai 0,208852681.

2) Hasil Ekstrasi Fitur Sudut 45°

Tabel 4 Ekstrasi fitur pada sudut 45°

No	Nama Image	Contrast	Homogeneity	Correlation	Energy	Kelas
1.	Image1	0,863574815	0,098878738	1060,703672	0,014731436	Layak
2.	Image2	0,869885115	0,138445352	1111,633819	0,036414867	Layak
3.	Image3	0,860397737	0,109663231	1192,359334	0,019297505	Layak
4.	Image4	0,874768872	0,115589523	1281,003492	0,019625935	Layak
5.	Image5	0,862961391	0,113761446	1261,350321	0,018568101	Layak
...
400	Image400	0,862781291	0,158610226	1480,915584	0,046935725	Tidak Layak

Berdasarkan Tabel 4 menyajikan hasil ekstraksi fitur pada sudut 45° , yang mencakup lima jenis fitur GLCM: Contrast, Homogeneity, Correlation dan Energy. Adapun rentang nilai dari masing-masing fitur yang ditampilkan dalam tabel tersebut adalah sebagai berikut: Contrast dari 1878,039969 sampai 1279,704165, Homogeneity dari 0,085354087 sampai 0,319247926, Correlation dari 0,770583619 sampai 0,891514143 dan energy dari 0,017220382 sampai 0,198511913.

3) Hasil Ekstrasi Fitur Sudut 90°

Tabel 5 Ekstrasi fitur pada sudut 90°

No	Nama Image	Contrast	Homogeneity	Correlation	Energy	Kelas
1.	Image1	0,888763469	0,123545846	900,5524327	0,016662733	Layak
2.	Image2	0,877672098	0,153443611	1085,129727	0,036166759	Layak
3.	Image3	0,890448607	0,126016537	975,3042275	0,020667538	Layak
4.	Image4	0,88333819	0,130167803	1222,237953	0,019549066	Layak
5.	Image5	0,905835079	0,138948095	903,9475894	0,021804801	Layak
...
400	Image400	0,874117446	0,172568784	1406,990189	0,045277009	Tidak Layak

Berdasarkan Tabel 5 menyajikan hasil ekstraksi fitur pada sudut 90° , yang mencakup lima jenis fitur GLCM: Contrast, Homogeneity, Correlation dan Energy. Adapun rentang nilai dari masing-masing fitur yang ditampilkan dalam tabel tersebut adalah sebagai berikut: Contrast dari 1757,805952 sampai 1472,732375, Homogeneity dari 0,16507638 sampai

0,331059739, Correlation dari 0,804318473 sampai 0,879884533 dan energy dari 0,049127356 sampai 0,195118764.

4) Hasil Ekstrasi Fitur Sudut 135°

Tabel 6 Ekstrasi fitur pada sudut 135°

No	Nama Image	Contrast	Homogeneity	Correlation	Energy	Kelas
1.	Image1	0,8578233	0,103103303	1105,454777	0,014880041	Layak
2.	Image2	0,873029815	0,142228569	1084,858233	0,037475045	Layak
3.	Image3	0,858789712	0,109256422	1206,220275	0,018748508	Layak
4.	Image4	0,88951805	0,127951904	1130,229483	0,020752752	Layak
5.	Image5	0,859551723	0,119689346	1292,910401	0,01917324	Layak
...
400	Image400	0,858807086	0,166044003	1524,490786	0,046949896	Tidak Layak

Berdasarkan Tabel 6 menyajikan hasil ekstraksi fitur pada sudut 135°, yang mencakup lima jenis fitur GLCM: Contrast, Homogeneity, Correlation dan Energy. Adapun rentang nilai dari masing-masing fitur yang ditampilkan dalam tabel tersebut adalah sebagai berikut: Contrast dari 867,1435206 sampai 1558,642406, Homogeneity dari 0,127135766 sampai 0,326288591, Correlation dari 0,895327112 sampai 0,867920832 dan energy dari 0,018234293 sampai 0,193836643.

3.2. Evaluasi

Untuk memperoleh hasil prediksi, dataset dibagi ke dalam dua jenis data, yaitu data latih serta data uji. Data pelatihan diperoleh untuk membentuk atau melatih model, sedangkan data pengujian dimanfaatkan sebagai menguji kemampuan prediksi model. Kinerja model kemudian dievaluasi dengan membandingkan label hasil prediksi dengan label aktual. Hasil evaluasi ini menghasilkan penanda yang menunjukkan apakah prediksi tersebut benar atau salah.

Untuk mengevaluasi kinerja model secara lebih mendalam, metrik seperti akurasi, presisi, dan recall dihitung berdasarkan confusion matrix yang dihasilkan. Confusion matrix ini menggambarkan jumlah prediksi yang benar dan salah, baik untuk kelas positif maupun negatif. Akurasi mengukur seberapa banyak prediksi yang benar, sedangkan presisi dan recall memberikan gambaran lebih detail tentang kinerja model dalam mengidentifikasi kelas tertentu. Berikut ini adalah contoh perhitungan metrik-metrik tersebut berdasarkan confusion matrix yang diperoleh dalam pengujian model.

Tabel 7 Sampel Confusion Matrix Kernel RBF

	Aktual: layak	Aktual: tidak layak	class precision
Prediksi: layak	TP: 113	FP: 20	84.96%
Prediksi: tidak layak	FN: 27	TN: 120	81.63 %
class recall	80.71%	85.71%	

Berdasarkan Tabel 7, dapat disimpulkan bahwa model klasifikasi dengan Kernel RBF menunjukkan kinerja yang cukup baik dalam membedakan antara kategori "layak" dan "tidak layak". Model memiliki precision sebesar 84,96% untuk prediksi "layak" dan 81,63% untuk

prediksi "tidak layak", yang berarti sebagian besar prediksi yang dibuat cukup akurat. Selain itu, recall sebesar 80,71% untuk kelas "layak" dan 85,71% untuk kelas "tidak layak" menunjukkan bahwa model cukup efektif dalam menangkap data yang benar untuk masing-masing kelas. Dengan demikian, model ini dapat diandalkan untuk tugas klasifikasi dalam konteks data yang digunakan.

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP+TN}{TP+TN+FP+FN} \\
 &= \frac{113+120}{113+20+27+120} \\
 &= \frac{233}{280} \\
 &= 0.832 * 100\% \\
 &= 83.2\%
 \end{aligned}$$

$$\begin{aligned}
 \text{Recall} &= \frac{TP}{TP+FN} \\
 &= \frac{113}{113+27} \\
 &= \frac{113}{140} \\
 &= 0.8071 * 100\% \\
 &= 80.71\%
 \end{aligned}$$

$$\begin{aligned}
 \text{Presisi} &= \frac{TP}{TP+FP} \\
 &= \frac{113}{113+20} \\
 &= \frac{113}{133} \\
 &= 0.8496 * 100\% \\
 &= 84.96\%
 \end{aligned}$$

1) Pengujian Klasifikasi Algoritma SVM

Tabel 8 Pengujian Algoritma SVM

Performance Sudut 0°	Performance Sudut 45°	Performance Sudut 90°	Performance Sudut 135°
83.71%	82.50%	82.14%	85.36%

Berdasarkan Tabel 8 menunjukkan hasil pengujian klasifikasi menggunakan algoritma SVM dengan kernel RBF pada empat sudut ketetanggaan. Hasil terbaik diperoleh pada sudut 135°, dengan akurasi sebesar 85,36%, menggunakan parameter Gamma sebesar 1.0 dan nilai C sebesar 0.0. Keempat sudut yang diuji merupakan hasil klasifikasi murni menggunakan SVM tanpa penerapan metode optimasi apa pun. Secara keseluruhan, nilai akurasi yang diperoleh pada masing-masing sudut adalah 83,71% untuk sudut 0°, 82,50% untuk sudut 45°, 82,14% untuk sudut 90°, dan 85,36% untuk sudut 135°.

2) Pengujian Optimasi Algoritma SVM dengan PSO

Tabel 9 Pengujian Algoritma SVM

Performance Sudut 0°	Performance Sudut 45°	Performance Sudut 90°	Performance Sudut 135°
91.43%	89.64%	90.00%	93.57%

Berdasarkan Tabel 9 menunjukkan bahwa pengujian algoritma SVM yang dioptimasi menggunakan PSO dengan kernel RBF menghasilkan performa terbaik sebesar 85,36% pada sudut 135°, dengan parameter Gamma sebesar 1.0 dan nilai C sebesar 0.0. Pada eksperimen kedua, digunakan dataset dan algoritma yang sama, namun kali ini ditambahkan proses optimasi dengan menggunakan *Particle Swarm Optimization* (PSO) sebagai mengevaluasi apakah PSO dapat meningkatkan atau justru menurunkan nilai akurasi metode tersebut. Pengujian dilakukan menggunakan RapidMiner Studio. Hasilnya, dari keempat sudut yang diuji, terjadi peningkatan akurasi pada sudut 135°, yaitu mencapai 93,57%. Nilai ini merupakan hasil klasifikasi murni dari kombinasi PSO-SVM.

3.3. Hasil Perbandingan

Untuk mengevaluasi keberhasilan penelitian ini dengan menggunakan dataset biji kopi medium roast, dapat dilihat bahwa klasifikasi dengan metode SVM dengan kernel *Radial Basis Function* (RBF) dan pada eksperimen kedua, metode yang sama digunakan namun dengan penambahan optimasi menggunakan *Particle Swarm Optimization* (PSO).

Perbandingan



Gambar 6 Grafik Hasil Perbandingan Akurasi SVM dan SVM + PSO

Berdasarkan Gambar 6 menampilkan grafik perbandingan akurasi (*accuracy*) antara metode SVM dan SVM yang dioptimasi dengan PSO (SVM + PSO) pada dataset biji kopi medium roast, menggunakan kernel *Radial Basis Function* (RBF). Grafik ini membandingkan hasil akurasi pada empat sudut pandang yang berbeda: 0°, 45°, 90°, dan 135°. Pada sudut 0°, akurasi SVM sebesar 83,71%, sedangkan SVM + PSO mencapai 91,43%. Untuk sudut 45°, SVM memiliki akurasi 82,5%, sementara SVM + PSO mencapai 89,64%. Pada sudut 90°, akurasi SVM adalah 82,14% dan SVM + PSO sebesar 90%. Terakhir, pada sudut 135°, SVM mencatat akurasi 85,36%, sedangkan SVM + PSO mencapai 93,57%. Secara keseluruhan, metode SVM + PSO

secara konsisten menunjukkan performa yang lebih baik dibandingkan SVM tanpa optimasi pada semua sudut pandang, dengan peningkatan akurasi yang signifikan.

4. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa ekstraksi fitur dan normalisasi data berperan penting dalam meningkatkan kinerja model Machine Learning. Ekstraksi fitur membantu menghilangkan atribut yang tidak relevan, sementara normalisasi dapat meningkatkan akurasi, khususnya pada metode tertentu seperti SVM dengan kernel RBF. Penggunaan parameter Gamma sebesar 1.0 dan nilai C sebesar 0.0 menunjukkan hasil terbaik saat data dinormalisasi. Selain itu, porsi data pelatihan yang lebih besar cenderung menghasilkan model yang lebih akurat.

Optimasi parameter menggunakan *Particle Swarm Optimization* (PSO) terbukti dapat meningkatkan akurasi terbaik pada klasifikasi SVM secara signifikan, dari 85,36% meningkat 8,21% menjadi 93,57% pada sudut 135°. Penerapan PSO pada SVM kernel RBF membentuk model yang efisien dan dapat diterapkan untuk menyortir biji kopi medium roast secara otomatis dan efisien. Untuk penelitian selanjutnya, disarankan mengeksplorasi optimasi PSO pada algoritma Machine Learning lainnya.

DAFTAR PUSTAKA

- [1] Edwin R Arboleda., Amel C. Fajardo., Ruji P. Medina., 2019 "An Image Processing Technique for Coffee Black Beans Identification," IEEE, ICIRD, 2018.
- [2] Jessie R. Balbin, Christian D. Del Valle, Van Julius Leander G Lopez, Rogelito F. Quiambao Jr, "Grading and Profiling of Coffee Beans for International Standards Using Integrated Image Processing Algorithm and Back-Propagation Neural Network," IEEE, HNICEM, 2020.
- [3] Raczko, E., & Zagajewski, B. (2017). Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. European Journal of Remote Sensing, 50(1), 144-154.
- [4] Kusuma, S. F., Pawening, R. E., & Dijaya, R. (2017). Otomatisasi klasifikasi kematangan buah mengkudu berdasarkan warna dan tekstur. Register: Jurnal Ilmiah Teknologi Sistem Informasi, 3(1), 17-23.
- [5] D. Wang, D. Tan, and L. Liu, "Particle swarm optimization algorithm: an overview," Soft Comput., vol. 22, pp. 387-408, 2018.
- [6] Pizzaia, J. P. L., Salcides, I. R., de Almeida, G. M., Contarato, R., & de Almeida, R. (2018, November). Arabica coffee samples classification using a Multilayer Perceptron neural network. In 2018 13th IEEE International Conference on Industry Applications (INDUSCON) (pp. 80-84). IEEE.
- [7] Putro, S., Prindo, B., & Soeelman, M. A. (2025). Optimasi Support Vector Machine Dengan PSO Untuk Klasifikasi Kelayakan Export Kerang Batik. Techno. com, 24(1).
- [8] Abbas Z., Rehman M.U., Najam S., Rizvi S.M.D., 2019 "An Efficient Gray-Level Co-Occurrence Matrix (GLCM) based Approach Towards Classification of Skin Lesion," IEEE, vol. 8, no. 2, pp. 317 - 321, 2019.
- [9] Zeeshan Abbas, Mobeen-ur-Rehman, Shahzaib Najam, S.M. Danish Rizvi, "An Efficient Gray-Level Co-Occurrence Matrix (GLCM) based Approach Towards Classification of Skin Lesion," IEEE, vol. 8, no. 2, pp. 317 - 321, 2019.
- [10] Aditya Budi Pradana, Prawito Prajitno, "A Portable Surface Roughness Measurement System Using Laser Speckle Imaging Based on GLCM," 2019 6th International Conference on Instrumentation, Control, and Automation (ICA), vol. 6, pp. 100 - 105, 31 July – 2 August 2019.

- [11] Ngadilan, M. A. A., Ismail, N., Rahiman, M. H. F., Taib, M. N., Ali, N. A. M., & Tajuddin, S. N. (2018, August). Radial Basis Function (RBF) tuned Kernel Parameter of Agarwood Oil Compound for Quality Classification using Support Vector Machine (SVM). In 2018 9th IEEE Control and System Graduate Research Colloquium (ICSGRC) (pp. 64-68). IEEE.
- [12] J. J. Remus and L. M. Collins, "Identifying impaired cochlear implant channels via speech-token confusion matrix analysis," ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc., vol. 4, pp. 741–744, 2007, doi: 10.1109/ICASSP.2007.367019.