

OPTIMISASI *HIPERPARAMETER TUNING* PADA METODE *SUPPORT VECTOR MACHINE* UNTUK KLASIFIKASI TINGKAT KEMATANGAN BUAH KOPI

Juprianus Rusman^{1*}, Berlian Zetikarya Haryati² dan Aryo Michael³

^{1,3}Program Studi Teknik Informatika, Universitas Kristen Indonesia Toraja, Jl. Nusantara No 12
Makale Tana Toraja

¹Email*: rusman.jr@ukitoraja.ac.id

³Email : arvomichael@ukitoraja.ac.id

²Program Studi Agroteknologi, Universitas Kristen Indonesia Toraja, Jl. Nusantara No 12 Makale
Tana Toraja

²Email: dewi_haryati@rocketmail.com

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang optimal untuk mengidentifikasi tingkat kematangan buah kopi berdasarkan fitur-fitur warna dari citra buah kopi. Fitur warna *red* (R), *green* (G) dan *blue* (B) pada ruang warna RGB dan *hue* (H), *saturation* (S), dan *value* (V) pada ruang warna HSV diekstraksi dari citra buah kopi dan digunakan sebagai *input* untuk model klasifikasi *support vector machine* (SVM). Agar kinerja SVM lebih optimal, digunakan *hyperparameter tuning* dengan metode *grid search* untuk penentuan parameter terbaik pada model klasifikasi yang dibangun. Dengan menggunakan 180 citra latih pada penentuan parameter optimum, diperoleh hasil *hyperparameter tuning* metode *grid search* yaitu pada *cross validation* (cv) = 6, *cost* (C) = 1000, *gamma* (γ) = 0,001, dan kernel = linear. Kemudian parameter optimum tersebut digunakan sebagai model SVM untuk mengklasifikasikan 45 citra uji ke dalam tiga kelas berbeda yakni matang, matang setengah, dan mentah. Berdasarkan evaluasi dengan *confusion matrix* dapat disimpulkan bahwa model yang dibangun memiliki kinerja yang baik dengan tingkat akurasi 98%. Hal ini mengindikasikan bahwa model yang dibangun mampu membedakan ketiga kelas dengan tingkat kesalahan yang rendah. Dengan kemampuan ini, model yang dibangun memiliki potensi dalam industri pertanian guna mendukung penggunaan teknologi pada bidang pertanian khususnya pertanian kopi seperti pengolahan buah pasca panen. Model ini dapat dikembangkan pada mesin penyortir tingkat kematangan buah kopi secara otomatis agar dapat meningkatkan kualitas dan efisiensi produksi serta membantu dalam pengambilan keputusan yang lebih baik.

Kata kunci: klasifikasi, tingkat kematangan, buah kopi, *support vector machine*, *hyperparameter tuning*

ABSTRACT

This study aims to develop an optimal classification model to identify the maturity level of coffee fruit based on color features of coffee fruit images. The color features red (R), green (G) and blue in RGB color space and hue (H), saturation (S), and value (V) in HSV color space are extracted from the coffee fruit image and used as input for the support vector machine (SVM) classification model. In order to optimize the performance of SVM, hyperparameter tuning is used with the grid search method to determine the best parameters in the classification model built. By using 180 training images in determining the optimum parameters, the hyperparameter tuning results of the grid search method are obtained at cross validation (cv) = 6, cost (C) = 1000, gamma (γ) = 0.001, and kernel = linear. Then the optimum parameters are used as an SVM model to classify 45 test images into three different classes, namely ripe, half ripe, and raw. Based on the evaluation with confusion matrix, it can be concluded that the built model has good performance with 98% accuracy. This indicates that the model is able to distinguish the three classes with a low error rate. With this ability, the model built has great potential in the agricultural industry to support the use of technology in agriculture, especially coffee farming such as post-harvest fruit processing. This model can be developed on a maturity level sorting machine.

Keywords : classification, maturity level, coffee fruit, support vector machine, hyperparameter tuning

1. PENDAHULUAN

Kopi memiliki peran yang penting dalam ekonomi Indonesia sebagai salah satu komoditi perkebunan. Selain sebagai produk ekspor, kopi juga berkontribusi dalam menghasilkan devisa negara,

*) Penulis Korespondensi

Dikirim : 10 September 2023

Diterima : 11 Oktober 2023

Publikasi Online : 31 Oktober 2023

pendapatan petani, dan membuka lapangan kerja. Kualitas kopi dipengaruhi banyak faktor mulai dari proses pengolahan, pengawasan dan pengendalian mutu, hingga penerapan teknologi dalam pengolahan kopi. Salah satu indikator untuk menghasilkan kopi yang baik ada tingkat kematangan buah kopi yang dapat dilihat dari perubahan warna buah kopi. Warna hijau pada buah kopi menandakan tingkat kematangan mentah, warna kekuningan hingga kemerahan menandakan tingkat kematangan matang setengah, sedangkan warna merah terang hingga merah gelap menandakan kopi dengan tingkat kematangan matang yang siap untuk dipanen. Praktik panen yang tidak selektif membuat buah kopi yang dipanen memiliki variasi tingkat kematangan yang kurang seragam yang dapat menurunkan kualitas kopi, sehingga perlu dilakukan penyortiran buah kopi pasca panen. Penyortiran buah kopi dilakukan dengan memilih dan memisahkan buah yang belum matang dari buah matang satu per satu. Namun proses ini dilakukan secara tradisional dan bersifat subjektif yang dapat menghasilkan variasi tingkat kematangan yang kurang seragam karena dipengaruhi faktor eksternal seperti pengaruh cahaya yang dapat mempengaruhi penglihatan petani saat melakukan penyortiran.

Dalam era Revolusi Industri 4.0, digitalisasi menjadi fokus utama [1], oleh karena itu *computer vision* menjadi salah satu teknologi penting dalam era Revolusi Industri 4.0. *Computer vision* adalah bidang yang mengkaji bagaimana komputer melihat objek kemudian mengubah menjadi format yang dapat diproses hingga dapat ditampilkan secara visual [2][3]. Pada penelitian ini dikembangkan konsep *computer vision* ke dalam industri kopi khususnya pengolahan buah kopi, yang merupakan langkah inovatif dalam meningkatkan efisiensi dan objektivitas dalam proses sortasi buah kopi. Teknik *image processing* dalam *computer vision* akan digunakan untuk memproses citra buah kopi, untuk mengklasifikasikan tingkat kematangan [4]. Klasifikasi tingkat kematangan buah kopi berdasarkan citra merupakan tantangan yang belum sepenuhnya dipecahkan. Terdapat kebutuhan akan metode yang dapat mengklasifikasikan buah kopi dengan tingkat akurasi yang tinggi, terutama pada kondisi yang bervariasi seperti perbedaan cahaya dan tekstur. *Support Vector Machine* (SVM) digunakan sebagai algoritma untuk melakukan klasifikasi berdasarkan fitur yang telah dipelajari dari data citra buah kopi. SVM adalah metode pembelajaran terawasi yang membutuhkan data latih dalam melakukan klasifikasi. Pemilihan metode SVM dalam penelitian ini adalah karena SVM telah terbukti efektif dalam masalah klasifikasi, terutama ketika terdapat dua atau lebih kelas yang harus dipisahkan dengan baik [5], seperti dalam kasus klasifikasi tingkat kematangan buah kopi yang dapat memiliki beberapa tingkat kematangan yang berbeda. SVM juga memiliki keunggulan dalam menangani data berdimensi tinggi [6], yang seringkali merupakan karakteristik dari citra digital.


Beberapa penelitian terdahulu telah menggunakan metode SVM untuk berbagai penelitian, seperti penelitian untuk mengklasifikasikan buah stroberi [7] dengan segmentasi warna HSV pada tiga tingkat kematangan. Penentuan parameter SVM yang dilakukan peneliti dengan mengganti-ganti nilai parameter secara manual, kemudian melihat akurasi dari setiap proses. Akurasi optimum yang diperoleh ialah 97%. Penelitian serupa yakni klasifikasi kematangan buah tomat ke dalam dua kelas menggunakan SVM dengan variasi ruang warna [5]. Peneliti membandingkan hasil klafikasi dengan fitur ruang warna HSV, YCbCr dan CIElab. Hasil klasifikasi SVM yang diperoleh dari model warna HSV sebesar 95%, YCbCr sebesar 74% dan CIElab sebesar 100%. Terdapat juga penelitian untuk mengklasifikasikan tujuh jenis pisang menggunakan metode SVM dan *K-Nearest Neighbourhood* (KNN) berdasarkan warna, bentuk, dan tekstur pisang [8]. Ruang warna yang digunakan adalah ruang warna *red*, *green* dan *blue* (RGB), *grayscale*, dan *biner*. Hasil klasifikais jenis pisang dengan algoritma SVM yang terbaik adalah fitur warna dengan akurasi 41,67% dan klasifikasi jenis pisang dengan algoritma KNN, K=2 dengan fitur tekstur memperoleh akurasi 58,33%. Selanjutnya penelitian untuk mengklasifikasi empat kelas citra daun anggur menggunakan SVM dengan kernel linear [9]. Peneliti menggunakan *squeezenet* untuk melakukan ekstraksi fitur. Akurasi yang diperoleh peneliti sebesar 98,1%.

Meskipun SVM merupakan metode pembelajaran yang bersifat terawasi dan telah digunakan dalam berbagai aplikasi klasifikasi, pengoptimalan *hyperparameter* SVM untuk klasifikasi buah kopi belum sepenuhnya dieksplorasi. Penggunaan teknik optimisasi *hyperparameter* dapat meningkatkan performa SVM [10]. Oleh karena itu, selain menerapkan teknik *computer vision*, penelitian ini juga berfokus pada optimisasi *hyperparameter* SVM. Adapun metode optimisasi yang digunakan adalah metode *Grid Search*. Pada metode ini, sejumlah kombinasi nilai *hyperparameter* yang telah ditentukan diatur dalam bentuk *grid*. Model dilatih dan dievaluasi untuk setiap kombinasi nilai *hyperparameter*, dan kombinasi yang memberikan hasil terbaik dipilih [11]. Dengan demikian, tantangan utama yang dihadapi dalam penelitian ini adalah bagaimana merumuskan optimisasi *hyperparameter* sehingga dapat mencapai kinerja yang optimal dari metode SVM dalam mengklasifikasikan citra buah kopi. Metode SVM yang dikombinasikan dengan optimisasi *hyperparameter* akan memberikan solusi yang potensial dalam mengklasifikasikan citra

buah kopi dengan akurasi tinggi, yang merupakan kontribusi signifikan dalam peningkatan proses penyortiran buah kopi pasca panen.

2. MATERI DAN METODE

Pada penelitian ini dilakukan serangkaian langkah yang sistematis dan terstruktur untuk mengatasi permasalahan klasifikasi tingkat kematangan buah kopi menggunakan metode SVM dengan pendekatan *computer vision*. Gambar 1 memperlihatkan langkah-langkah yang dilakukan.



Gambar 1. Tahapan penelitian

Akuisisi Data

Dataset berupa citra buah kopi dengan tiga tingkat kematangan yakni mentah, matang setengah, dan matang yang dikumpulkan dengan beberapa variasi sudut pandang. Contoh citra *dataset* ditunjukkan pada Gambar 2.




a. Mentah b. Matang setengah c. Matang

Gambar 2. Citra *dataset*

Jumlah *dataset* yang digunakan sebanyak 225 citra yang terdiri dari 75 citra per kelas tiap tingkat kematangan. *Dataset* dibagi menjadi data latih dan data uji dengan pembagian 80%:20% dan memastikan keseimbangan distribusi tingkat kematangan dalam kedua *dataset*. Komposisi pembagian *dataset* yakni 180 citra untuk data latih masing-masing 60 citra per kelas tingkat kematangan dan 45 citra untuk data uji masing-masing 15 citra per kelas tingkat kematangan.

Image Processing

Image processing adalah proses persiapan citra digital sebelum dilakukan analisis atau pengolahan lebih lanjut. Hal ini melibatkan beberapa langkah untuk meningkatkan kualitas, kejernihan, dan relevansi citra, termasuk pemotongan, penghilangan *noise*, peningkatan kontras, pengubahan ruang warna, dan teknik lainnya. Tujuan utama dari *image preprocessing* adalah mempermudah ekstraksi fitur, deteksi objek, atau analisis lebih lanjut pada citra digital [7][12]. Dalam *image processing* dilakukan dua proses, yakni *cropping* dan *resize*. *Cropping* dilakukan untuk memperkecil ukuran citra dengan mengambil bagian citra yang dibutuhkan kemudian dilakukan *resize* citra dengan ukuran 250 x 250 piksel untuk menyeragamkan ukuran citra. Gambar 3 memperlihatkan hasil proses *image processing*.



a. Citra Awal

b. Crop citra

c. Resize citra 250 x 250 piksel

Gambar 3. Hasil proses *image processing*

Pada penelitian ini, tidak dilakukan proses segmentasi berhubung warna *background* dari citra yaitu warna putih sudah kontras dengan warna buah kopi. Oleh sebab itu tahapan selanjutnya yaitu proses konversi ruang warna citra yang bertujuan untuk mengurangi dampak dari iluminasi pada citra buah kopi. Seluruh *dataset* diubah dari ruang warna RGB ke ruang warna HSV seperti yang ditunjukkan pada Gambar 4. Nilai *Hue* menunjukkan spektrum warna atau corak yang ada seperti hijau, kuning, dan merah.

Sedangkan nilai *saturation* menunjukkan tingkat kemurnian warna dan *value* menunjukkan ukuran kecerahan citra [7][13]. Gambar 4 merupakan hasil konversi citra buah kopi ke ruang warna HSV.



Gambar 4. Citra ruang warna HSV

Ekstraksi Fitur

Proses ekstraksi fitur merupakan proses mencari fitur yang membedakan kelas objek. Dalam penelitian ini, fitur yang digunakan adalah fitur warna buah kopi karena warna pada buah kopi merupakan indikator tingkat kematangan. Fitur yang digunakan adalah fitur warna *red* (R), *green* (G), dan *blue* (B) pada ruang warna RGB dan *hue* (H), *saturation* (S) dan *value* (V) pada ruang warna HSV. Fitur pada citra HSV diambil dengan mencari nilai H, S, dan V menggunakan Persamaan 1 sampai dengan Persamaan 4 dengan R merupakan nilai komponen warna merah, G merupakan nilai komponen warna hijau, B merupakan nilai komponen warna biru, C max merupakan nilai maksimum diantara komponen RGB, C min merupakan nilai minimum diantara komponen RGB, dan C = selisih nilai C maksimum dengan C minimum [7].

$$\begin{aligned} C \max &= \max (R, G, B) \\ C \min &= \min (R, G, B) \\ C &= C \max - C \min \end{aligned} \quad (1)$$

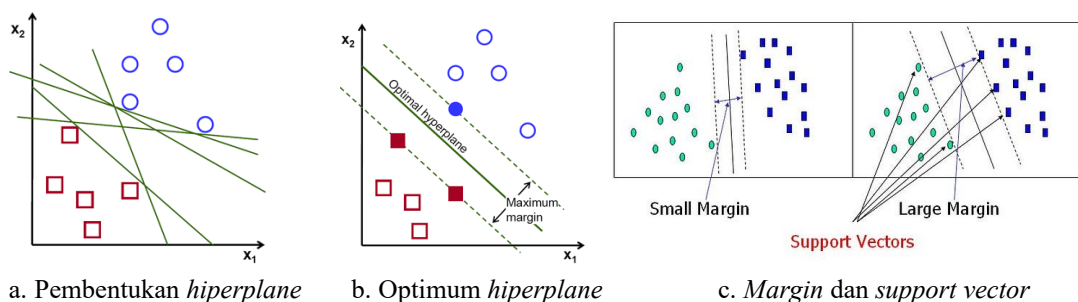
$$H = \begin{cases} 0, & \text{jika } C \max = C \min \\ 60 \left(\frac{G-B}{C} \% 6 \right), & \text{jika } C \max = R \\ 60 \left(\frac{B-R}{C} + 2 \right), & \text{jika } C \max = G \\ 60 \left(\frac{R-G}{C} + 4 \right), & \text{jika } C \max = B \end{cases} \quad (2)$$

$$S = \begin{cases} 0, & \text{jika } C \max = 0 \\ \frac{C}{C \max}, & \text{jika } C \max \neq 0 \end{cases} \quad (3)$$

$$V = C \max \quad (4)$$

Pembentukan Model

Metode klasifikasi yang digunakan adalah SVM yaitu salah satu algoritma pembelajaran mesin yang digunakan untuk pemisahan kelas dalam data. SVM bertujuan untuk mencari *hyperplane* (bidang pemisahan) yang paling baik memisahkan dua kelas data dengan jarak maksimum antara *hyperplane* dan titik-titik data terdekat dari masing-masing kelas. Prinsip dasar SVM adalah berdasarkan pemisahan linear, dengan tujuan utama adalah mencari *hyperplane* yang memiliki margin maksimum, yang menunjukkan ketahanan model terhadap data baru atau generalisasi yang baik. SVM juga memiliki kemampuan untuk menangani data yang tidak dapat dipisahkan secara linear dalam ruang fitur asli, melalui penggunaan fungsi kernel seperti kernel *linier*, *polynomial*, dan *radial basis function* (RBF). SVM memiliki parameter *cost* (C) yang mengatur tingkat kesalahan klasifikasi, dapat digunakan mengontrol *trade-off* antara margin maksimum dan akurasi klasifikasi. Titik-titik data yang berada tepat di atas atau tepat di bawah margin disebut *vektor dukungan* (*support vector*) dan memiliki peran penting dalam menentukan *hyperplane* pemisah [8][14]. Gambar 5 merupakan ilustrasi prinsip kerja SVM.



Gambar 5. Ilustrasi prinsip kerja metode SVM

Pembangunan model SVM melibatkan pemilihan parameter yang mempengaruhi model seperti pemilihan jenis kernel, C , dan γ untuk percepatan fungsi pada kernel. Pemilihan parameter ini adalah tahapan untuk memastikan model SVM dapat bekerja dengan baik dalam mengklasifikasikan data. Dalam penerapannya menggunakan fungsi $svm.SVC()$. Fungsi ini memungkinkan untuk membuat model SVM dengan berbagai parameter yang dapat disesuaikan dengan jenis dan karakteristik data.

Hyperparameter Tuning

Penentuan parameter pada tahap pembangunan model akan dioptimalkan dengan menggunakan metode *hyperparameter tuning* yaitu sebuah metode yang digunakan untuk mengkombinasikan parameter yang relevan. Metode *hyperparameter* yang digunakan adalah metode *grid search* yaitu metode yang digunakan dalam pembelajaran mesin untuk mencari kombinasi terbaik dari parameter (model) dengan menguji semua kemungkinan kombinasi yang telah ditentukan dalam sebuah *grid*. *Grid Search* membantu dalam menentukan parameter yang optimal untuk meningkatkan kinerja model [11][15]. Parameter yang memberikan hasil terbaik dipilih sebagai model dari SVM. Adapun konfigurasi *hyperparameter* yang digunakan diperlihatkan pada Tabel 1.

Tabel 1. *Hyperparameter* Pemanding

<i>Hyperparameter</i>	<i>Value</i>
Kernel	<i>Linear, Polynomial, RBF, Sigmoid</i>
<i>Cost (C)</i>	0,1; 1; 10; 100; 1000
<i>Gamma (γ)</i>	0,001; 0,01; 0,1; 1

Pengujian Model SVM

Pengujian model SVM menggunakan data uji yang fiturnya telah diekstraksi sebelumnya dan menggunakan parameter optimal yang ditemukan pada tahap optimisasi *hyperparameter tuning* metode *grid search*. Data pengujian sebanyak 45 citra masing 15 citra untuk kelas “matang”, “matang setengah”, dan “mentah”.

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negative (TN)	False Positive (FP) Type I Error
	Positive +	False Negative (FN) Type II Error	True Positive (TP)

Gambar 6. Evaluasi metode *confusion matrix*

Hasil pengujian dievaluasi dengan menggunakan *confusion matrix* yang merupakan metode evaluasi model klasifikasi pada data yang memiliki label kelas yang sudah diketahui. *Confusion matrix* terdiri dari empat nilai, yakni *true positive* (TP) yang merupakan jumlah kasus positif diklasifikasikan dengan benar oleh model, *false positive* (FP) yang merupakan jumlah kasus negatif yang salah diklasifikasikan sebagai positif oleh model, *false negative* (FN) yang merupakan jumlah kasus positif yang salah diklasifikasikan

sebagai negatif oleh model, dan *true negative* (TN) yang merupakan jumlah kasus negatif yang diklasifikasikan dengan benar oleh model [9][15]. Evaluasi *confusion matrix* ditunjukkan pada Gambar 6.

3. HASIL DAN PEMBAHASAN

Hasil dari tahapan selanjutnya setelah tahap *image procesing* yaitu tahap ekstraksi fitur, dijabarkan sebagai berikut. Fitur RGB pada setiap citra diperoleh dengan menghitung nilai rata-rata komponen RGB kemudian dilakukan normalisasi (skala 0 sampai 1) dengan cara membagi nilai rata-rata komponen RGB yang diperoleh dengan nilai 255 yang merupakan nilai piksel maksimal pada ruang warna RGB. Sebagai contoh citra buah kopi pada Gambar 3 (c) (*dataset file Matang (7).jpg*) dapat diketahui nilai $R = 0,595$; $G = 0,378$ dan $B = 0,355$. Selanjutnya dengan menggunakan Persamaan 1 maka diperoleh nilai $C_{max} = 0,598$; $C_{min} = 0,355$, dan $C = 0,239$, sedangkan untuk menghitung nilai HSV digunakan Persamaan 2 sampai Persamaan 4.

$$H = 60 \left(\frac{0,378 - 0,355}{0,239} \% 6 \right)$$

$$= 5,889$$

$$S = \frac{0,239}{0,595}$$

$$= 0,402$$

$$V = 0,595$$

Proses ekstraksi fitur diberlakukan pada seluruh data latih dan data uji untuk mengidentifikasi ciri-ciri warna yang terkait dengan kelas buah kopi “matang”, “matang setengah”, dan “mentah”. Hasil ekstraksi fitur masing-masing kategori tersebut kemudian dicatat dan diberi label sesuai kelasnya sebagai bagian dari *dataset* latih yang akan digunakan dalam proses pengembangan model klasifikasi. Hal yang serupa juga dilakukan terhadap data uji. Pada Tabel 2 merupakan hasil proses ekstraksi fitur data latih.

Tabel 2. Fitur data latih

No	File	Red	Green	Blue	Hue	Saturation	Value	Label
1	Matang (1).jpg	0,55795382	0,365387671	0,352837898	3,6710283	0,367621682	0,55795382	Matang
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
60	Matang (60).jpg	0,363642227	0,306028612	0,307134745	358,8480501	0,158434888	0,363642227	Matang
61	Matang Setengah (1).jpg	0,666841788	0,411894902	0,359648502	10,20459802	0,46066892	0,666841788	Matang Setengah
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
120	Matang Setengah (60).jpg	0,564057725	0,465119498	0,345212235	32,87449862	0,387984209	0,564057725	Matang Setengah
121	Mentah (1).jpg	0,466224314	0,539385537	0,443043137	105,5632558	0,178615097	0,539385537	Mentah
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
180	Mentah (60).jpg	0,386278337	0,428182902	0,363686337	98,98306668	0,150628538	0,428182902	Mentah


Pada tahap penentuan parameter optimum dilakukan beberapa kali uji coba kombinasi parameter yang telah ditentukan pada Tabel 1 dengan parameter *cross validation* pada metode *grid search*. *Cross validation* adalah teknik pada *machine learning* yang membagi *dataset* menjadi subset, lalu melatih dan menguji model pada subset tersebut secara berulang. Hal ini membantu mengukur kinerja model dan mencegah *overfitting* serta memastikan bahwa model dapat melakukan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya. Pada tahap ini data latih digunakan untuk memperoleh parameter optimum yang ditandai dengan akurasi terbaik pada setiap kombinasi parameter *hyperparameter grid search*. Hasil yang diperoleh pada penentuan parameter optimum metode *hyperparameter grid search* ditampilkan pada Tabel 3.

Tabel 3. Parameter dan akurasi metode *hyperparameter grid search*

Cross Validation (CV)	Cost (C) optimum	Gamma (γ) optimum	Kernel optimum	Akurasi
2	0,1	1	poly	0,92777
3	1000	0,001	rbf	0,98333
4	1000	0,001	linear	0,98888
5	1000	0,001	linear	0,98888

6 1000 0,001 linear 0,99444

Berdasarkan Tabel 3, dapat diketahui bahwa akurasi terbaik metode *grid search* yaitu 0,994 diperoleh pada kombinasi parameter *cross validation* (*cv*) = 6 dengan parameter yang sama yaitu $C = 1000$, $\gamma = 0,001$, dan kernel = 'linear'. Dengan demikian maka parameter tersebut yang merupakan parameter optimum. Selanjutnya parameter optimum tersebut digunakan sebagai model SVM (*cross validation* tidak digunakan pada SVM), kemudian dilakukan proses pengujian dengan data uji. Tahap pengujian dengan data uji dilanjutkan dengan tahap evaluasi kinerja model dengan memperhatikan akurasi dari model yang dihasilkan berdasarkan *confusion matrix*. Hasil pengujian model SVM yang dibangun ditunjukkan pada Gambar 7.



Gambar 7. *Confusion matrix* hasil pengujian

Pada Gambar 7 dapat dilihat bahwa model klasifikasi telah diuji pada tiga kelas yang berbeda yaitu “matang”, “matang setengah”, dan “mentah”. Model yang dibangun memiliki kinerja yang baik dalam membedakan ketiga kelas tersebut. Pada data aktual “matang” tidak ada yang salah prediksi untuk kelas lain, di mana terdapat 15 prediksi yang benar untuk kelas “matang”. Hal yang serupa pada data aktual kelas “mentah” di mana terdapat 15 prediksi yang benar untuk kelas “mentah” dan tidak ada prediksi yang salah terhadap kelas lain. Pada data aktual “matang setengah” terdapat satu prediksi yang salah ke kelas “matang”. Namun secara keseluruhan performa model masih dapat dikategorikan baik dengan 14 prediksi yang benar untuk kelas “matang setengah”.

Pada pengujian dengan data uji sebanyak 45 data, diperoleh tingkat akurasi model yang dibangun mencapai 0,98 atau 98% yang menunjukkan bahwa sebagian besar prediksi yang dibuat oleh model adalah benar dengan tingkat kesalahan yang sangat rendah. Dengan kata lain, model ini cukup efektif dalam mengklasifikasikan sampel buah kopi menjadi tiga kelas yang berbeda dan hasil pengujian ini menunjukkan bahwa model tersebut dapat digunakan dengan baik dalam konteks klasifikasi buah kopi matang, matang setengah dan mentah.

4. KESIMPULAN DAN SARAN

Parameter optimum diperoleh dengan *hyperparameter tuning* metode *grid search* pada parameter *cross validation* = 6, $C = 1000$, $\gamma = 0.001$, dan kernel = linear dengan akurasi 0,99444. Pada pengujian 45 citra data uji dengan model SVM untuk mengklasifikasikan buah kopi menjadi tiga kelas berbeda yaitu ‘matang’, ‘matang setengah’, dan ‘mentah’ mendapat hasil yang baik. Dari hasil evaluasi dengan *confusion matrix* dapat disimpulkan bahwa model yang dibangun memiliki kinerja yang baik dengan tingkat akurasi 98%. Hal ini mengindikasikan bahwa model yang dibangun mampu membedakan ketiga kelas dengan tingkat kesalahan yang rendah. Dengan kemampuan ini, model yang dibangun memiliki potensi besar dalam industri pertanian khususnya pertanian kopi seperti pengolahan buah pasca panen untuk sortasi tingkat kematangan buah kopi agar dapat meningkatkan kualitas dan efisiensi produksi serta membantu dalam pengambilan keputusan yang lebih baik.

Berdasarkan hasil temuan tersebut, maka beberapa saran dapat dilakukan pada penelitian berikutnya seperti ekspansi *dataset*, meskipun pada penelitian ini diperoleh hasil yang memuaskan namun memperluas atau menambahkan *dataset* lebih banyak variasi dalam tingkat kematangan dapat membantu memeriksa apakah model ini tetap efektif dalam situasi yang lebih beragam. Selain itu, dapat dilakukan penambahan fitur dengan penambahan fitur lain selain fitur warna, seperti tekstur atau ukuran buah kopi, dapat meningkatkan kemampuan model untuk mengklasifikasikan buah kopi, serta melakukan eksperimen lapangan dengan menerapkan model ini dalam pengolahan buah kopi yang sesungguhnya dan mengamati kinerja dalam lingkungan yang sebenarnya.

DAFTAR PUSTAKA

- [1] E. Prakasa, "Computer Vision dan Artificial Intelligence di Era Revolusi Industri 4.0," General Lecture in Universitas Riau 28 October 2021, Oct. 28, 2021, doi: <http://dx.doi.org/10.13140/RG.2.2.26229.09448>.
- [2] H. Fitriyah and R. C. Wihandika, *Dasar-Dasar Pengolahan Citra Digital*. Universitas Brawijaya Press, 2021.
- [3] M. Z. Andrekha and Y. Huda, "Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan Opencv Python," *Voteteknika Vocat. Tek. Elektron. Dan Inform.*, vol. 9, no. 4, pp. 27–33, Dec. 2021, doi: <https://doi.org/10.24036/voteteknika.v9i4.114251>.
- [4] Seema et al., "Automatic Fruit Grading and Classification System Using Computer Vision: A Review," in *2015 Second International Conference on Advances in Computing and Communication Engineering*, 2015, pp. 598–603, doi: <https://doi.org/10.1109/ICACCE.2015.15>.
- [5] N. Astrianda, "Klasifikasi Kematangan Buah Tomat Dengan Variasi Model Warna Menggunakan Support Vector Machine," *VOCATECH Vocat. Educ. Technol. J.*, vol. 1, pp. 45–52, Apr. 2020, doi: <https://doi.org/10.38038/vocatech.v1i2.27>.
- [6] I. Indrabayu et al., "Strawberry Ripeness Classification System Based On Skin Tone Color using Multi-Class Support Vector Machine," in *2019 International Conference on Information and Communications Technology (ICOLACT)*, 2019, pp. 191–195, doi: <https://doi.org/10.1109/ICOIACT46704.2019.8938457>.
- [7] I. S. Areni et al., "Klasifikasi Kematangan Stroberi Berbasis Segmentasi Warna dengan Metode HSV," *J. Penelit. Enj.*, vol. 23, no. 2, pp. 113–116, Nov. 2019, doi: <http://dx.doi.org/10.25042/jpe.112019.03>.
- [8] Y. E. Yana and N. Nafi'iyah, "Klasifikasi Jenis Pisang Berdasarkan Fitur Warna, Tekstur, Bentuk Citra Menggunakan SVM dan KNN," *Res. J. Comput. Inf. Syst. Technol. Manag.*, vol. 4, no. 1, pp. 28–36, Apr. 2021, doi: <http://doi.org/10.25273/research.v4i1.6687>.
- [9] A. G. Sooi et al., "Klasifikasi Citra Daun Anggur Menggunakan SVM Kernel Linear," *JOINTECS J. Inf. Technol. Comput. Sci.*, vol. 8, no. 1, pp. 19–26, Mar. 2023, doi: <https://doi.org/10.31328/jointecs.v8i1.4496>.
- [10] K. Kr et al., "An Improved Feature Selection and Classification of Gene Expression Profile using SVM," in *2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)*, 2019, vol. 1, pp. 1033–1037, doi: <https://doi.org/10.1109/ICICT46008.2019.8993358>.
- [11] M. Fajri and A. Primajaya, "Komparasi Teknik Hyperparameter Optimization pada SVM untuk Permasalahan Klasifikasi dengan Menggunakan Grid Search dan Random Search," *J. Appl. Inform. Comput.*, vol. 7, no. 1, pp. 10–15, Jul. 2023, doi: <https://doi.org/10.30871/jaic.v7i1.5004>.
- [12] P. C. Upadhyay et al., "Classifying Cover Crop Residue from RGB Images: A Simple SVM versus a SVM Ensemble," in *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2021, pp. 1–7, doi: <https://doi.org/10.1109/SSCI50451.2021.9660147>.
- [13] M. M. Chandra and Yoannita, "Klasifikasi Jenis Bunga Menggunakan Metode Svm Berdasarkan Citra Dengan Fitur Hsv," *J. Indones. Sos. Teknol.*, vol. 4, no. 02, pp. 255–264, Feb. 2023, doi: <https://doi.org/10.59141/jist.v4i02.585>.
- [14] Y. Dong et al., "A Machine Learning Model for Product Fraud Detection Based On SVM," in *2021 2nd International Conference on Education, Knowledge and Information Management (ICEKIM)*, 2021, pp. 385–388, doi: <https://doi.org/10.1109/ICEKIM52309.2021.00091>.
- [15] Z. M. E. Darmawan and A. F. Dianta, "Implementasi Optimasi Hyperparameter GridSearchCV Pada Sistem Prediksi Serangan Jantung Menggunakan SVM," *Teknol. J. Ilm. Sist. Inf.*, vol. 13, no. 1, pp. 8–15, Jan. 2023, doi: <https://doi.org/10.26594/teknologi.v13i1.3098>.