

Analisis Fitur Warna dan Tekstur pada Klasifikasi Rasa Buah Jeruk Medan Menggunakan Metode Support Vector Machine

Asteniva Gultom¹, Supatman²

^{1,2} Informatika, Universitas Mercu Buana Yogyakarta

e-mail: ¹ 221110115@student.mercubuana-yogya.ac.id, ² supatman@mercubuana-yogya.ac.id

Abstract – Determining the taste of citrus fruit without tasting it directly remains a real challenge for Medan Orange farmers and traders to this day. The method commonly used is to taste each fruit directly, whereas this approach damages the fruit and cannot be applied to large quantities of fruit at the same time. This study analyzes color and texture features of the fruit skin surface to classify the taste of Medan Orange into sweet, bland, and sour categories using the Support Vector Machine (SVM) method. SVM was selected due to its proven effectiveness in handling data with a large number of features resulting from image extraction, as well as its ability to find the best decision boundary between classes compared to other methods such as K-Nearest Neighbor and Decision Tree. A total of 496 fruit images were collected directly from the field, consisting of three classes: sweet (183 images), bland (113 images), and sour (200 images). Color features were extracted from the HSV and LAB color spaces, while texture features were extracted using the Gray Level Co-occurrence Matrix (GLCM). From the evaluation of five feature configurations, the HSV+LAB configuration was selected as the final configuration as it produced an accuracy of 79.00% with the fastest processing time. The sour class was recognized best with an F1-score of 0.89, followed by the sweet class at 0.84, while the bland class obtained 0.47 due to its color falling between the other two classes. These results indicate that image-based citrus taste classification has potential as a non-destructive fruit selection tool, enabling farmers and traders to assess taste quality quickly without damaging the fruit.

Keywords – Medan Orange, Taste Classification, HSV, LAB, GLCM, Support Vector Machine

Abstrak – Menentukan rasa buah jeruk tanpa mencicipinya secara langsung masih menjadi tantangan nyata bagi petani dan pedagang Jeruk Medan hingga saat ini. Cara yang digunakan selama ini yaitu mencicipi langsung setiap buah, padahal cara ini merusak buah dan tidak bisa dilakukan untuk banyak buah dalam waktu yang sama. Penelitian ini menganalisis fitur warna dan tekstur permukaan kulit buah untuk mengklasifikasikan rasa Jeruk Medan manis, hambar, dan asam menggunakan metode Support Vector Machine (SVM). SVM dipilih karena kemampuannya yang terbukti efektif dalam menangani data dengan jumlah fitur yang banyak hasil dari ekstraksi citra, serta mampu menemukan batas pemisah terbaik antar kelas dibandingkan metode lain seperti K-Nearest Neighbor maupun Decision Tree. Sebanyak 496 foto buah dikumpulkan langsung dari lapangan yang terdiri dari tiga kelas: manis (183 foto), hambar (113 foto), dan asam (200 foto). Fitur warna diekstraksi dari ruang warna HSV dan LAB, sedangkan fitur tekstur diekstraksi menggunakan Gray Level Co-occurrence Matrix (GLCM). Dari pengujian lima konfigurasi fitur, konfigurasi HSV+LAB dipilih sebagai konfigurasi final karena menghasilkan akurasi 79,00% dengan waktu proses paling cepat. Kelas asam dikenali paling baik dengan F1-score 0,89, diikuti kelas manis 0,84, sementara kelas hambar memperoleh 0,47 karena warnanya berada di antara dua kelas lainnya. Hasil ini menunjukkan bahwa klasifikasi rasa jeruk berbasis citra berpotensi sebagai alat bantu seleksi buah non-destruktif, sehingga petani dan pedagang dapat menilai kualitas rasa secara cepat tanpa harus merusak buah.

Kata Kunci – Jeruk Medan, Klasifikasi Rasa, HSV, LAB, GLCM, Support Vector Machine

I. PENDAHULUAN

Jeruk manis (*Citrus sinensis*) khususnya Jeruk Medan merupakan salah satu komoditas buah yang memiliki kontribusi terbesar terhadap produksi hortikultura di Indonesia dan menjadi komoditas unggulan dari wilayah Sumatera Utara [1]. Buah ini banyak tumbuh di dataran tinggi Kabupaten Karo dengan kondisi tanah dan iklim yang sangat cocok. Produksinya terus meningkat setiap tahun, menjadikannya komoditas penting di pasar lokal maupun nasional. Namun di balik popularitasnya, Jeruk Medan memiliki variasi rasa yang sangat tinggi. Dalam satu keranjang bisa terdapat buah yang manis, hambar, bahkan asam, meskipun tampilannya hampir sama.

Cara yang digunakan selama ini untuk menentukan rasa adalah dengan mencicipi langsung. Cara ini tidak praktis karena merusak buah yang diuji, hasilnya tergantung pada selera penilai, dan tidak bisa dilakukan untuk ratusan buah dalam waktu singkat [2]. Ini menjadi hambatan bagi petani dan pedagang dalam menjaga konsistensi kualitas produk.

Perkembangan teknologi pengolahan citra digital membuka peluang untuk mengatasi masalah ini. Muallaf et al. [3] berhasil mengklasifikasikan kematangan jeruk lemon menggunakan SVM dengan akurasi 97%. Prihastinur [4] menerapkan Multi-Class SVM berbasis warna HSV untuk kematangan buah naga dengan akurasi 86,67%. Arifuddin [5] membuktikan SVM lebih unggul dari Naive Bayes untuk jenis Citrus dengan akurasi 96,36%. Kiswanto [6] mengidentifikasi variasi paprika menggunakan SVM dengan akurasi 97,56%. Mindara [7] membandingkan KNN dan SVM untuk kematangan Jeruk Medan dengan hasil 96,25%.

Namun kebanyakan penelitian tersebut hanya menargetkan kematangan buah, bukan rasanya. Padahal kematangan dan rasa adalah dua hal yang berbeda jeruk yang warnanya oranye belum tentu manis karena rasa juga dipengaruhi kandungan gula, jenis tanah, dan pola pemupukan [7]. Warna kulit buah jeruk dapat mencerminkan perubahan yang terjadi di dalam buah dan berkaitan dengan rasanya. Amalina et al. [8] menunjukkan bahwa kandungan gula pada buah jeruk yang diukur melalui nilai total padatan terlarut memiliki korelasi dengan perubahan warna kulit, di mana buah berwarna lebih kuning cenderung memiliki kandungan gula yang lebih tinggi. Selain itu, selama proses pematangan, zat hijau pada kulit buah (klorofil) akan berubah menjadi zat berwarna kuning hingga oranye (karotenoid) yang terjadi bersamaan dengan meningkatnya kandungan gula dan berkurangnya rasa asam pada buah. Oleh karena itu, warna kulit berpotensi digunakan sebagai indikator tidak langsung dalam menentukan rasa buah jeruk [8]. Belum ada penelitian yang menganalisis fitur warna dan tekstur secara bersamaan untuk mengklasifikasikan rasa Jeruk Medan [9].

Berdasarkan celah tersebut, penelitian ini berkontribusi untuk menganalisis fitur warna (HSV dan LAB) dan fitur tekstur (GLCM) dalam mengklasifikasikan rasa Jeruk Medan manis, hambar, dan asam menggunakan metode SVM. Lima konfigurasi fitur diuji secara sistematis untuk menemukan kombinasi terbaik

II. PENELITIAN YANG TERKAIT

A. Klasifikasi Buah Berbasis Citra Digital

Barranco-Gutiérrez et al. [10] mengembangkan sistem klasifikasi mutu buah jeruk secara non-destruktif menggunakan deskriptor citra berbasis GLCM yang dikombinasikan dengan metode ANFIS dan diterbitkan di jurnal Agriculture (MDPI, Scopus Q1). Penelitian ini membuktikan fitur tekstur GLCM mampu membedakan tingkat kemanisan dan kekerasan jeruk, dan menjadi acuan utama penggunaan GLCM dalam penelitian ini. Riza et al. [11] memprediksi kematangan Jeruk Pontianak menggunakan fitur warna dan tekstur dari citra digital dengan model PLS, mengonfirmasi bahwa kombinasi kedua jenis fitur memberikan informasi lebih kaya dibandingkan fitur tunggal. Dhiman et al. [12] merangkum lebih dari 100 penelitian evaluasi kualitas buah dan menyimpulkan SVM adalah pilihan yang baik untuk data di bawah 1.000 sampel karena kemampuan generalisasinya yang baik. Meski demikian, ketiga penelitian tersebut masih memiliki keterbatasan masing-masing. Granados-Lieberman et al. [10] menggunakan metode ANFIS yang proses pengaturannya lebih rumit dibandingkan SVM, sehingga kurang praktis digunakan pada data lapangan dalam jumlah kecil. Riza et al. [11] menggunakan model PLS yang lebih sesuai untuk memprediksi nilai angka secara langsung, bukan untuk mengelompokkan data ke dalam beberapa kelas seperti yang dibutuhkan dalam penelitian ini. Sementara itu, Dhiman et al. [12] hanya memberikan rekomendasi berdasarkan kajian literatur tanpa melakukan pengujian secara langsung, sehingga hasilnya masih bersifat umum dan perlu dibuktikan pada kasus nyata seperti klasifikasi rasa buah jeruk.

B. Penelitian Kualitas dan Rasa Jeruk

Albattah et al. [13] membuktikan nilai warna RGB permukaan jeruk berkorelasi kuat dengan kemanisannya dengan akurasi prediksi 97% dan diterbitkan di Applied Sciences (MDPI, Scopus Q2). Ini menjadi bukti ilmiah bahwa warna permukaan jeruk memang punya hubungan nyata dengan rasanya. Zeb et al. [14]

mengklasifikasikan kemanisan tiga jenis jeruk ke tiga kelas manis, campuran, dan asam menggunakan sensor NIR gelombang pendek dan diterbitkan di Scientific Reports (Scopus Q1). Meski hasilnya baik, sensor NIR sangat mahal dan tidak praktis bagi petani kecil, sehingga penelitian ini menawarkan pendekatan lebih terjangkau menggunakan kamera biasa. Malau et al. [9] mengklasifikasikan rasa Jeruk Berastagi menggunakan gabungan warna dan GLCM dengan SVM penelitian paling dekat topiknya, namun menggunakan varietas berbeda, tanpa LAB, dan tanpa perbandingan sistematis antar konfigurasi fitur. Mindara [7] membandingkan KNN dan SVM untuk kematangan Jeruk Medan (KNN 96,25%, SVM 91,25%), namun fokusnya kematangan bukan rasa. Secara keseluruhan, penelitian-penelitian tersebut menunjukkan bahwa warna buah memang berhubungan dengan kualitas rasa, namun masing-masing masih memiliki kekurangan. Albattah et al. [13] hanya menggunakan 50 sampel dengan dua kelas saja, sehingga hasilnya belum tentu berlaku pada kondisi nyata di lapangan yang lebih beragam. Zeb et al. [14] meskipun menghasilkan akurasi yang baik, menggunakan sensor NIR yang harganya sangat mahal dan tidak terjangkau oleh petani kecil. Malau et al. [9] merupakan penelitian yang paling mendekati penelitian ini, namun belum menguji ruang warna LAB dan belum membandingkan berbagai kombinasi fitur secara menyeluruh, sehingga belum diketahui apakah kombinasi fitur lain dapat menghasilkan kinerja yang lebih baik.

C. Support Vector Machine untuk Klasifikasi Citra

Wang et al. [15] membandingkan SVM, Random Forest, KNN, dan CNN di Pattern Recognition Letters (Elsevier, Scopus Q1). SVM terbukti lebih unggul dari CNN pada data kecil-menengah karena CNN dibutuhkan ribuan sampel, hal ini mendukung pemilihan SVM untuk 496 citra dalam penelitian ini. Faisal [16] juga menggunakan SVM lebih stabil dibandingkan KNN untuk klasifikasi citra tomat dengan berbagai variasi kondisi citra. Namun perlu dicatat bahwa Wang et al. [15] melakukan pengujian pada data gambar umum, bukan gambar buah yang diambil langsung dari lapangan yang memiliki variasi pencahayaan dan latar belakang yang lebih beragam. Faisal [16] pun hanya menguji satu jenis buah dalam kondisi yang sudah diatur sebelumnya, sehingga keunggulan SVM masih perlu dibuktikan pada data Jeruk Medan yang dikumpulkan langsung dari lapangan dengan kondisi pengambilan gambar yang lebih bervariasi.

D. Perbedaan dengan Penelitian Sebelumnya

Penelitian ini memiliki empat keunggulan dibanding penelitian sebelumnya: (1) menganalisis fitur warna dan tekstur secara bersamaan untuk klasifikasi rasa, (2) spesifik pada Jeruk Medan sebagai varietas lokal Sumatera Utara, (3) membandingkan lima konfigurasi fitur secara sistematis dilengkapi waktu proses, (4) menggunakan Grid Search untuk optimasi parameter secara otomatis. Perbandingan dengan penelitian sebelumnya disajikan pada Tabel I.

TABEL I
PERBANDINGAN DENGAN PENELITIAN TERDAHULU


Ref	Subjek	Metode	Data	Target	Perbedaan
[8]	Jeruk	ANFIS+GLCM	Primer	Kemanisan & tekstur	Bukan klasifikasi rasa 3 kelas
[9]	Jeruk Pontianak	PLS+warna+tekstur	Primer	Kematangan	Kematangan, bukan rasa
[11]	Jeruk	RGB	50 sampel	Kemanisan (2 kelas)	Hanya 2 kelas, bukan 3
[12]	Jeruk Pakistan	NIR Spectroscopy	3 Varietas	Rasa (3 kelas)	Sensor mahal, bukan kamera
[7]	Jeruk Medan	KNN vs SVM	Lapangan	Kematangan	Kematangan, bukan rasa
[13]	Jeruk Berastagi	SVM+GLCM	Lapangan	Rasa	Varietas beda, tanpa LAB, tanpa perbandingan fitur
Penelitian ini	Jeruk Medan	SVM+Grid Search	496 citra	Rasa (3 kelas)	Analisis 5 konfigurasi fitur, HSV+LAB+GLCM

III. METODE PENELITIAN

A. Alur Penelitian

Gambar 1 menampilkan alur kerja penelitian dari awal hingga akhir. Penelitian dimulai dari pengumpulan 496 citra Jeruk Medan, dilanjutkan pelabelan rasa secara manual oleh tiga penguji, pra-proses citra, ekstraksi 16

fitur warna dan tekstur, pembagian data latih dan uji, pelatihan SVM (Support Vector Machine) dengan Grid Search, evaluasi model, hingga menghasilkan klasifikasi kelas rasa buah.



Gbr. 1 Alur Sistem Klasifikasi Rasa Buah Jeruk Medan

B. Data

Data terdiri dari 496 citra buah Jeruk Medan yang dikumpulkan secara langsung di lapangan. Data dibagi menjadi tiga kelas berdasarkan hasil cicip dan ditentukan manis (183 citra), hambar (113 citra), dan asam (200 citra). Citra diambil menggunakan kamera smartphone beresolusi minimal 12 MP dengan dua lampu LED daylight 6500K dan latar belakang putih yang sama. Pengambilan citra diambil pada jarak 30 cm. Setiap buah dinilai oleh tiga penguji dan kelas ditetapkan berdasarkan suara terbanyak. Mekanisme pemungutan suara mayoritas ini diterapkan untuk mengurangi pengaruh penilaian yang bersifat subjektif dari satu orang penguji. Ketiga penguji melakukan penilaian secara terpisah tanpa saling mengetahui hasil penilaian satu sama lain, sehingga keputusan akhir yang diambil mencerminkan kesepakatan bersama. Pendekatan ini sesuai dengan prinsip kesepakatan antar penilai yang umum digunakan dalam penelitian yang melibatkan pelabelan data secara subjektif.

TABEL II
JUMLAH DATA PER KELAS

Kelas	Total	Pelatihan (80%)	Pengujian (20%)	Proporsi
Manis	183	146	37	36,9%
Hambar	113	91	22	22,8%
Asam	200	160	40	40,3%
Total	496	397	99	100%

C. Praproses Citra

Setiap citra diproses melalui empat tahap: (1) Ukuran diubah menjadi 128×128 piksel menggunakan interpolasi bilinear atau pengubahan ukuran citra berdasarkan rata-rata piksel di sekitarnya sehingga citra terlihat jelas dan semua citra memiliki ukuran yang konsisten, (2) Latar belakang putih dihapus menggunakan threshold HSV (*Hue Saturation Value*) sehingga hanya area buah yang akan dianalisis, (3) Citra dihaluskan menggunakan Gaussian Blur untuk menghilangkan bintik-bintik kecil yang muncul akibat proses penyimpanan citra, sehingga warna yang dianalisis benar-benar menampilkan warna kulit jeruk yang sesungguhnya, (4) Nilai piksel dinormalisasikan ke rentang 0–1 agar dapat konsisten antar citra.

D. Ekstraksi Fitur Warna dan Tekstur

Penelitian ini mengekstraksi dua jenis fitur dari setiap citra: 12 fitur warna dan 4 fitur tekstur, total 16 fitur per citra.

1) Fitur Warna HSV (*Hue Saturation Value*)

Setiap citra diubah ke warna HSV yang memisahkan warna, kepekatan, dan kecerahan secara terpisah. Pemisahan ini membuat analisis warna lebih stabil meskipun cahaya saat pengambilan citra berbeda-beda. Dari setiap channel H, S, dan V diambil dua nilai, rata-rata menggambarkan warna citra dominan secara keseluruhan, dan standar deviasi (nilai dari rata-rata yang menggambarkan beragam warna) dalam citra tersebut. Dari ketiga channel maka diperoleh total 6 fitur warna HSV.

TABEL III
DESKRIPSI 6 FITUR WARNA HSV

Nama Fitur	Keterangan
Mean Hue (μH)	Warna dominan kulit jeruk. Manis $\approx 18,4$ (oranye), Asam $\approx 41,6$ (kuning-hijau)
Std Hue (σH)	Seberapa bervariasi warna dominan dalam satu citra
Mean Saturation (μS)	Kepekatan warna. Manis $\approx 198,3$ (pekat), Asam $\approx 103,4$ (pucat). Fitur terkuat.
Std Saturation (σS)	Variasi kepekatan warna dalam citra
Mean Value (μV)	Kecerahan kulit. Manis $\approx 207,6$ (cerah), Asam $\approx 158,9$ (gelap)
Std Value (σV)	Variasi kecerahan dalam citra

2) Fitur Warna LAB

Citra juga diubah ke format warna LAB, perbedaan angka di LAB mencerminkan perbedaan warna yang benar-benar bisa dilihat oleh mata. LAB memiliki tiga komponen informasi warna yang terpisah. L untuk mengukur seberapa terang atau gelap permukaan jeruk, A untuk mengukur kandungan warna merah atau hijau, dan B untuk mengukur kandungan warna kuning atau biru. Dari masing-masing komponen diambil nilai rata-rata dan standar deviasi, menghasilkan 6 fitur tambahan yang melengkapi fitur HSV sebelumnya.

TABEL IV
DESKRIPSI 6 FITUR WARNA LAB

Nama Fitur	Keterangan
Mean Lightness (μL)	Tingkat terang/gelap permukaan. Rentang 0 (hitam) – 100 (putih)
Std Lightness (σL)	Variasi kecerahan dalam citra
Mean a (μa)	Sumbu hijau–merah. Manis $\approx 148,2$ (lebih merah/oranye)
Std a (σa)	Variasi kandungan warna merah-hijau
Mean b (μb)	Sumbu biru–kuning. Asam $\approx 140,1$ (lebih kuning)
Std b (σb)	Variasi kandungan warna biru-kuning

3) Fitur Tekstur GLCM (Gray Level Co-occurrence Matrix)

Fitur tekstur diekstraksi menggunakan GLCM, sebuah metode yang menganalisis kecerahan antar piksel yang berdekatan pada citra. Pengecekan dilakukan dari empat arah berbeda (0° , 45° , 90° , 135°) kemudian dirata-rata agar hasilnya lebih stabil. Dari analisis ini diperoleh empat nilai: Contrast yang menggambarkan kekasaran tekstur kulit, Correlation yang menggambarkan keteraturan pola piksel, Energy yang menggambarkan keseragaman tekstur, dan Homogeneity yang menggambarkan kemiripan piksel-piksel yang berdekatan.

TABEL V
DESKRIPSI FITUR TEKSTUR GLCM

Nama Fitur	Keterangan
Contrast	Kekasaran tekstur kulit jeruk
Correlation	Pola keteraturan antar piksel tetangga
Energy	Keseragaman pola tekstur permukaan
Homogeneity	Kemiripan nilai piksel yang berdekatan

E. Pembagian Data dan Normalisasi

Data dibagi menjadi 80% untuk melatih model (397 citra) dan 20% untuk menguji model (99 citra). Pembagian dilakukan secara merata agar ketiga kelas mendapatkan jumlah citra yang sebanding. Sebelum dimasukkan ke model SVM, semua fitur disamakan skalanya agar fitur tidak mendominasi fitur tertentu yang hanya karena nilainya lebih besar. Penyamaan skala ini diperoleh dari data latih dan kemudian diterapkan ke data uji, sehingga hasil pengujian benar-benar menggambarkan kemampuan fitur yang sesungguhnya.

F. Model SVM dan Optimasi Parameter dengan Grid Search

Model SVM bekerja dengan mencari garis pemisah terbaik yang bisa memisahkan kelas-kelas data dengan jarak yang paling jauh. Semakin jauh jarak pemisahannya, semakin baik model dalam mengenali data baru. Dalam

penelitian ini, SVM digunakan untuk memisahkan tiga kelas rasa jeruk manis, hambar, dan asam berdasarkan 16 fitur yang sudah diekstraksi.

Untuk menemukan parameter terbaik, digunakan Grid Search yaitu cara yang otomatis untuk mencoba semua kemungkinan kombinasi model SVM. Grid Search melakukan berbagai kombinasi nilai C, gamma, dan jenis kernel secara otomatis, kemudian memilih kombinasi yang menghasilkan akurasi tertinggi. Tanpa Grid Search, pemilihan parameter ini harus dilakukan satu per satu secara manual yang membutuhkan waktu yang cukup lama. Parameter yang diuji dalam Grid Search meliputi nilai C yaitu 0,1; 1; 10; 50; dan 100 yang berfungsi mengatur seberapa ketat model dalam menghindari kesalahan pengelompokan, nilai gamma dengan pilihan 'scale', 'auto', 0,001; 0,01; dan 0,1 yang berfungsi mengatur seberapa jauh pengaruh setiap data terhadap hasil pengelompokan, serta dua jenis kernel yaitu RBF dan Linear. Keseluruhan kombinasi tersebut menghasilkan 50 kemungkinan kombinasi parameter yang diuji secara otomatis oleh sistem.

Untuk mengurangi risiko model yang hanya menghafal data latih tanpa mampu mengenali data baru, Grid Search digabungkan dengan validasi silang 5 lipatan. Artinya, setiap kombinasi parameter diuji sebanyak lima kali menggunakan bagian data latih yang berbeda-beda, kemudian hasilnya diambil rata-ratanya. Cara ini menghasilkan rata-rata akurasi sebesar $76,76\% \pm 2,39\%$, yang menunjukkan bahwa model yang dihasilkan cukup stabil dan dapat diandalkan.

G. Evaluasi Model

Model dievaluasi menggunakan empat metrik yaitu akurasi, presisi, recall, dan F1-score. Rumus masing-masing metrik adalah sebagai berikut:

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total data uji}} \times 100\% \quad (1)$$

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

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

$$\text{F1 - Score} = \frac{2 \times (\text{Presisi} \times \text{Recall})}{\text{Presisi} + \text{Recall}} \quad (4)$$

Keterangan:

TP = True positive (citra yang benar diklasifikasikan ke kelasnya).

TN = True negative (citra yang benar tidak masuk ke kelas lain).

FP = False positive (citra yang salah masuk ke suatu kelas).

FN = False negative (citra yang seharusnya masuk ke suatu kelas tapi terlewat).

IV. HASIL DAN PEMBAHASAN

A. Perbandingan 5 Konfigurasi Fitur

Tabel VII menyajikan hasil perbandingan lima konfigurasi fitur secara sistematis, dilengkapi akurasi dan waktu proses. Semua pengujian dilakukan pada mesin yang sama untuk perbandingan yang adil.

TABEL VII
KINERJA AKURASI BERDASARKAN FITUR

No	Konfigurasi	Akurasi	Waktu Ekstraksi	Waktu Pelatihan	Waktu Prediksi
1	HSV	67,00%	73,5s	7,2s	236,40ms
2	LAB	70,00%	70,2s	5,8s	167,11ms
3	HSV + LAB	79,00%	142,6s	7,4s	251,68ms
4	GLCM	46,00%	87,7s	4,1s	149,85ms
5	HSV+LAB+GLCM	79,00%	230,5s	8,0s	410,32ms

Dari Tabel VII terlihat beberapa hasil utama. Pertama, fitur warna jauh lebih kuat dari fitur tekstur untuk membedakan rasa jeruk terbukti dari GLCM yang hanya menghasilkan akurasi 46,00%. Kedua, kombinasi HSV+LAB menghasilkan akurasi 79,00% penambahan GLCM tidak meningkatkan akurasi tetapi menambah waktu prediksi dari 251,68ms menjadi 410,32ms. Ketiga, LAB (70,00%) lebih baik dari HSV (67,00%), ini menunjukkan LAB lebih mampu membedakan ketiga kelas rasa Jeruk Medan. Konfigurasi HSV+LAB dipilih sebagai konfigurasi akhir karena menghasilkan akurasi tertinggi 79,00% dengan waktu proses paling cepat, yaitu waktu ekstraksi 142,6 detik, waktu pelatihan 7,4 detik, dan waktu prediksi 251,68 ms. Meskipun konfigurasi HSV+LAB+GLCM menghasilkan akurasi yang sama sebesar 79,00%, waktu prosesnya jauh lebih

lama sehingga tidak dipilih sebagai konfigurasi akhir. Apabila dibandingkan dengan penelitian sejenis, akurasi 79,00% yang diperoleh dalam penelitian ini memang berada di bawah beberapa penelitian sebelumnya. Malau et al. [9] yang mengklasifikasikan rasa Jeruk Berastagi menggunakan SVM dengan fitur HSV dan GLCM berhasil mencapai akurasi pengujian sebesar 96,67% dengan rata-rata akurasi validasi silang 93,33%. Lapendy et al. [17] yang mengklasifikasikan rasa Jeruk Siam menggunakan jaringan saraf tiruan dengan fitur LAB dan GLCM mencapai akurasi sebesar 98,75%. Namun perbedaan ini dapat dipahami dan dijelaskan melalui tiga faktor utama. Pertama, kedua penelitian tersebut menggunakan jenis jeruk yang berbeda dengan warna kulit yang lebih beragam sehingga lebih mudah dikenali oleh model. Kedua, penelitian ini menggunakan tiga kelas rasa termasuk kelas hambar yang sulit dibedakan secara visual, sementara penelitian pembandingan hanya menggunakan dua kelas. Ketiga, data dalam penelitian ini dikumpulkan langsung dari lapangan tanpa seleksi ketat sehingga lebih mencerminkan kondisi nyata, namun dengan tingkat variasi data yang lebih tinggi.

B. Nilai Rata-rata Fitur per Kelas

Tabel VIII menampilkan rata-rata nilai 16 fitur tiap kelas rasa, dihitung menggunakan Persamaan (1). Fitur bertanda ✓ menunjukkan perbedaan yang cukup besar antar kelas.

TABEL VIII
RATA-RATA NILAI 16 FITUR PER KELAS RASA

Fitur	Manis (183)	Hambar (113)	Asam (200)	Selisih Manis–Asam
Mean Hue (HSV)	18,4	27,9	41,6	23,2 ✓
Std Hue (HSV)	7,2	8,5	9,1	1,9
Mean Saturation (HSV)	198,3	151,7	103,4	94,9 ✓
Std Saturation (HSV)	21,4	19,8	22,1	0,7
Mean Value (HSV)	207,6	183,2	158,9	48,7 ✓
Std Value (HSV)	14,8	16,3	17,5	2,7
Mean Lightness (LAB)	132,4	128,7	121,3	11,1 ✓
Std Lightness (LAB)	12,1	11,8	12,4	0,3
Mean a (LAB)	148,2	136,4	122,7	25,5 ✓
Std a (LAB)	10,3	9,8	10,1	0,2
Mean b (LAB)	118,3	126,8	140,1	21,8 ✓
Std b (LAB)	9,8	10,2	10,5	0,7
Contrast (GLCM)	0,312	0,298	0,341	0,043
Correlation (GLCM)	0,891	0,887	0,878	0,013
Energy (GLCM)	0,043	0,041	0,039	0,004
Homogeneity (GLCM)	0,847	0,851	0,839	0,012


Dari Tabel VIII terlihat fitur warna memiliki selisih jauh lebih besar dibandingkan fitur tekstur GLCM. Mean Saturation adalah fitur terkuat dengan selisih 94,9 unit antara kelas manis dan asam. Fitur GLCM memiliki selisih yang sangat kecil antar kelas (Contrast: 0,043; Homogeneity: 0,012), mengonfirmasi bahwa tekstur kulit Jeruk Medan tidak berbeda secara signifikan antar kelas rasa. Keunggulan fitur warna dibandingkan fitur tekstur ini dapat dijelaskan dari sisi karakteristik biologis buah jeruk. Rasa manis, hambar, dan asam pada jeruk berkaitan erat dengan kandungan gula dan asam yang terbentuk selama proses pematangan buah. Proses pematangan ini berjalan bersamaan dengan perubahan zat hijau pada kulit buah (klorofil) menjadi zat berwarna kuning hingga oranye (karotenoid), sehingga menghasilkan perubahan warna yang tampak dari luar. Dengan demikian, warna kulit buah secara tidak langsung mencerminkan perubahan kandungan kimia di dalam buah. Di sisi lain, tekstur permukaan kulit jeruk cenderung tidak banyak berubah meskipun kandungan gulanya berbeda, sehingga fitur tekstur yang diekstraksi menggunakan GLCM kurang mampu membedakan ketiga kelas rasa secara akurat. Keterkaitan ini juga terlihat jelas dari data pada Tabel VIII. Nilai Mean Saturation kelas manis yang mencapai 198,3 mencerminkan warna kulit yang lebih pekat dan gelap, yang sesuai dengan kandungan gula yang lebih tinggi pada buah yang sudah matang penuh. Sebaliknya, kelas asam memiliki nilai Mean Saturation hanya 103,4 yang mencerminkan warna kulit yang lebih pucat, sesuai dengan kandungan asam yang masih tinggi dan gula yang belum terbentuk sepenuhnya. Nilai Mean Hue juga menunjukkan pola yang

sama, di mana kelas manis memiliki nilai 18,4 yang berarti warna kulit cenderung oranye, sementara kelas asam memiliki nilai 41,6 yang berarti warna kulit masih cenderung kuning kehijauan. Pola ini menunjukkan bahwa perubahan warna kulit jeruk berjalan seiring dengan perubahan kandungan kimia di dalam buah, sehingga fitur warna dapat digunakan sebagai penanda tidak langsung untuk membedakan rasa jeruk.

Untuk melihat apakah perbedaan nilai fitur antar kelas cukup berarti secara statistik, dapat digunakan uji Kruskal-Wallis sebagai pilihan yang sesuai karena data fitur citra tidak selalu mengikuti sebaran data yang normal. Sebagai gambaran awal, perbedaan nilai rata-rata Saturation antara kelas manis dan asam mencapai 94,9 dari rentang nilai 0–255, yang menunjukkan perbedaan yang sangat besar. Demikian pula nilai rata-rata Hue dengan selisih 23,2 dan nilai rata-rata a LAB dengan selisih 25,5 menunjukkan bahwa kedua kelas tersebut dapat dipisahkan dengan cukup jelas. Sebaliknya, seluruh fitur tekstur GLCM memiliki selisih nilai di bawah 0,05 yang menandakan tidak adanya perbedaan yang berarti antar kelas rasa.

C. Hasil Klasifikasi dan Confusion Matrix

Pengujian pada 99 data uji menghasilkan akurasi 79,00% artinya 79 dari 99 citra berhasil diklasifikasikan dengan benar. Gambar 2 menampilkan confusion matrix dan grafik F1-score per kelas dari hasil pengujian ini.



Gbr. 2 Hasil Klasifikasi Rasa Buah Jeruk Medan

TABEL IX
HASIL EVALUASI MODEL SVM PER KELAS

Kelas	Presisi	Recall	F1-Score	Jumlah
Manis	0,79	0,89	0,84	37
Hambar	0,60	0,39	0,47	23
Asam	0,86	0,93	0,89	39
Weighted Avg	0,79	0,79	0,79	99

D. Perhitungan Metrik Manual

Berikut perhitungan manual untuk kelas Manis menggunakan Persamaan (1)–(4). Dari confusion matrix: TP=33 (manis benar), FP=9 (data dari kelas lain yang salah diprediksi sebagai Manis), FN=4 (manis yang salah diklasifikasi):

$$\text{Presisi}_{\text{manis}} = \frac{TP}{TP+FP} = \frac{33}{33+9} = \frac{33}{42} = 0,79$$

$$\text{Recall}_{\text{manis}} = \frac{TP}{TP+FN} = \frac{33}{33+4} = \frac{33}{37} = 0,89$$

$$F1_{\text{manis}} = \frac{2 \times (\text{Presisi} \times \text{Recall})}{\text{Presisi} + \text{Recall}} = \frac{2 \times (0,79 \times 0,89)}{0,79 + 0,89} = 0,84$$

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total data uji}} \times 100\% = \frac{33+9+37}{99} \times 100\% = \frac{79}{99} \times 100\% = 79,00\%$$

Nilai 33, 9, dan 37 merupakan nilai diagonal confusion matrix yang merepresentasikan jumlah prediksi benar untuk masing-masing kelas Manis, Hambar, dan Asam. Rumus TP+TN tidak digunakan secara langsung karena pada klasifikasi multikelas, nilai TN dihitung berbeda untuk setiap kelas. Sebagai referensi, TN untuk kelas Manis = 54, diperoleh dari jumlah seluruh prediksi benar di luar kelas Manis (9+6+2+37). Untuk kelas Asam:

TP=37, FP=6, FN=3, sehingga Presisi=0,86, Recall=0,93, F1=0,89. Hasil ini sesuai dengan output `classification_report()` dari `scikit-learn` pada kode.

E. Analisis Performa per Kelas

Kelas asam Adalah kelas yang paling mudah dikenali ($F1=0,89$) karena warna kulitnya kuning kehijauan yang sangat berbeda dari kelas lain. Kelas manis juga cukup baik ($F1=0,84$) karena warnanya oranye tua yang cukup mencolok. Kelas hambar merupakan kelas yang paling sulit dikenali, dari 22 citra hambar yang diuji, hanya 9 yang benar dikenali, 8 salah (dianalisis manis), dan 5 salah (dianalisis asam). Ini terjadi karena warna jeruk hambar berada di antara warna manis dan asam, sehingga model kesulitan memisahkan secara pasti.

F. Analisis Citra yang Salah Diklasifikasikan

Gambar 3 menampilkan contoh citra yang salah diklasifikasi. Terlihat bahwa citra yang salah umumnya memiliki warna yang berada di perbatasan antara dua kelas, terutama antara hambar dengan manis atau asam. Ini mengonfirmasi bahwa kesalahan bukan karena algoritma yang buruk, melainkan karena warna jeruk hambar secara visual memang mirip dengan kelas lain.



Gbr. 3 Contoh Citra Jeruk yang Salah Diklasifikasikan

G. Keterbatasan Penelitian

Penelitian ini memiliki empat keterbatasan yang perlu diakui. Pertama, kelas hambar adalah yang paling sulit dikenali ($F1=0,47$) karena warnanya berada di antara manis dan asam, ditambah jumlahnya paling sedikit (113 citra). Kedua, semua citra diambil dalam kondisi cahaya yang sudah diatur di dalam ruangan, sehingga belum diketahui apakah model tetap akurat jika citra diambil di luar ruangan dengan cahaya yang berubah-ubah. Ketiga, rasa hambar bersifat ambigu dan batasannya dengan manis atau asam bisa berbeda tergantung selera penguji, sehingga beberapa citra mungkin diberi label yang kurang tepat. Keempat, dengan 496 citra total jumlah data masih tergolong sedikit, data belum cukup untuk metode yang membutuhkan data yang sangat banyak [15]. Untuk mengatasi keterbatasan tersebut, beberapa pendekatan dapat dipertimbangkan pada penelitian selanjutnya. Pertama, ketidakseimbangan jumlah data antar kelas terutama kelas hambar yang hanya berjumlah 113 citra dapat diatasi menggunakan teknik penambahan data sintetis seperti SMOTE (Synthetic Minority Oversampling Technique), yaitu cara untuk membuat data baru yang mirip dengan data kelas yang jumlahnya sedikit sehingga model tidak condong ke kelas yang lebih banyak. Kedua, penambahan jenis fitur lain seperti fitur bentuk buah atau fitur yang diperoleh dari cahaya inframerah berpotensi membantu model membedakan kelas hambar yang secara visual mirip dengan kelas manis dan asam. Ketiga, penggunaan metode pembelajaran mendalam seperti Convolutional Neural Network (CNN) yang mampu mengenali pola visual secara otomatis tanpa perlu mengekstraksi fitur secara manual dapat menjadi alternatif yang menarik untuk dieksplorasi pada penelitian berikutnya.

V. KESIMPULAN

Penelitian ini berhasil menganalisis fitur warna dan tekstur untuk mengklasifikasikan rasa buah Jeruk Medan dengan kelas manis, hambar, dan asam dengan menggunakan metode SVM. Dari pengujian lima konfigurasi fitur pada 496 foto, konfigurasi HSV+LAB dipilih sebagai konfigurasi akhir karena menghasilkan akurasi tertinggi 79,00% dengan waktu proses paling cepat dibandingkan konfigurasi lain yang memiliki akurasi sama.

Model SVM dengan kernel linear menghasilkan akurasi 79,00%. Fitur warna terbukti jauh lebih kuat dari fitur tekstur dalam membedakan rasa jeruk Mean Saturation memiliki selisih 94,9 unit antar kelas, sedangkan selisih terbesar GLCM hanya 0,043. Kelas asam berhasil diklasifikasikan paling baik ($F1=0,89$), diikuti kelas manis ($F1=0,84$), sementara kelas hambar masih menjadi tantangan ($F1=0,47$) karena warnanya berada di antara dua kelas lainnya. Untuk penelitian selanjutnya, disarankan menambah jumlah foto terutama kelas hambar dan mencoba pengambilan foto dalam kondisi cahaya yang berbeda-beda. Dari sisi penerapan, pendekatan berbasis fitur warna HSV dan LAB yang tidak membutuhkan banyak daya komputasi ini berpotensi dikembangkan menjadi aplikasi di ponsel pintar yang dapat digunakan langsung oleh petani di lapangan untuk menilai rasa jeruk secara cepat tanpa perlu merusak atau membelah buah. Selain itu, hasil penelitian ini juga membuka peluang untuk diterapkan pada sistem pemilahan buah otomatis di tingkat distributor, di mana kamera dan perangkat pemroses sederhana sudah cukup untuk menjalankan model ini tanpa memerlukan perangkat yang mahal. Untuk penelitian selanjutnya, disarankan untuk menambah jumlah data terutama pada kelas hambar, mencoba teknik penyeimbangan data seperti SMOTE, mencoba pengambilan foto dalam kondisi cahaya yang berbeda-beda, serta mengeksplorasi penambahan jenis fitur lain atau penggunaan metode pembelajaran mendalam seperti Convolutional Neural Network (CNN) guna meningkatkan kemampuan model dalam membedakan kelas rasa yang secara visual memiliki kemiripan.

DAFTAR PUSTAKA

- [1] E. P. Yudha and A. Nugraha, "Analisis Daya Saing Komoditas Jeruk Indonesia di Pasar Internasional," *Jurnal Ilmiah Mahasiswa AGROINFO GALUH*, vol. 10, no. 2, pp. 1514–1528, 2023. [Online]. Available: <https://jurnal.unigal.ac.id/agroinfohaluh/article/view/16174>
- [2] S. Napitu, R. P. Panjaitan, P. A. Nulhakim, and M. K. Lubis, "Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan HSV Menggunakan Metode KNN," *Jurnal Saintekom*, vol. 13, no. 2, pp. 214–221, 2023. doi: 10.33020/saintekom.v13i2.420.
- [3] D. Muallifah, H. Rivaldi, J. Al Amin, and Sunanto, "Klasifikasi Buah Jeruk Lemon Berdasarkan Tingkat Kematangan Menggunakan Metode SVM dan Naive Bayes," *Journal of Software Engineering and Information System*, vol. 5, no. 2, pp. 114–121, 2025. [Online]. Available: <https://ejurnal.umri.ac.id/index.php/SEIS/article/view/9952>
- [4] Prihastinur, "Klasifikasi Kematangan Buah Naga Berdasarkan Fitur Warna Menggunakan Algoritma Multi-Class Support Vector Machine," *JINTEKS*, vol. 5, no. 1, pp. 121–126, 2023. doi: 10.51401/jinteks.v5i1.2203.
- [5] N. A. Arifuddin, "Komparasi Naïve Bayes dan Support Vector Machine dalam Klasifikasi Jenis Citrus," *Techno.Com*, vol. 22, no. 2, pp. 409–417, 2023. doi: 10.33633/tc.v22i2.7777.
- [6] D. Kiswanto, "Identifikasi Variasi Paprika Berbasis Analisis Citra Digital Menggunakan Algoritma SVM," *ISAINTEK*, vol. 7, no. 2, pp. 209–220, 2024. doi: 10.55606/isaintek.v7i2.282.
- [7] G. P. Mindara, "Perbandingan Kinerja Algoritma KNN dan SVM dalam Klasifikasi Kematangan Buah Jeruk Medan Berdasarkan Citra Digital," *SKANIKA*, vol. 9, no. 1, pp. 159–170, 2026. doi: 10.36080/skanika.v9i1.3661.
- [8] A. N. Amalina *et al.*, "Perubahan Warna dan Total Padatan Terlarut pada Jeruk, Tomat, serta Jagung setelah Perebusan," *Journal of Food and Culinary*, vol. 8, no. 1, pp. 1–10, 2025.
- [9] M. L. Malau, S. Wulandari, and D. Kiswanto, "Penerapan Pengolahan Citra Digital untuk Klasifikasi Rasa Jeruk Berastagi Berdasarkan Warna dan Tekstur dengan Metode Klasifikasi SVM," *Jurnal Pendidikan Teknologi Informasi dan Vokasional*, vol. 7, no. 1, pp. 86–101, 2025. doi: 10.23960/jptiv.v7i1.32589.
- [10] D. Granados-Lieberman *et al.*, "Non-Destructive Classification of Sweetness and Firmness in Oranges Using ANFIS and a Novel CCI-GLCM Image Descriptor," *Applied Sciences*, vol. 15, no. 19, p. 10464, 2025. doi: 10.3390/app151910464.

- [11] D. F. A. Riza, Y. Hendrawan, and N. Kondo, "Prediction of the Maturity Level of Pontianak Oranges Using Color and Texture Features of Digital Reflectance-Fluorescence Images and PLS Model," *Proceedings of the 2023 Brawijaya International Conference*, pp. 125–132, 2024. doi: 10.2991/978-94-6463-525-6_14.
- [12] B. Dhiman, Y. Kumar, and M. Kumar, "Fruit Quality Evaluation Using Machine Learning Techniques: Review, Motivation and Future Perspectives," *Multimedia Tools and Applications*, vol. 81, pp. 16255–16277, 2022. doi: 10.1007/s11042-022-11939-8.
- [13] W. Albattah, M. Nawaz, A. Javed, M. Masood, and S. Albahli, "Predicting Fruit's Sweetness Using Artificial Intelligence — Case Study: Orange," *Applied Sciences*, vol. 12, no. 16, p. 8233, 2022. doi: 10.3390/app12168233.
- [14] A. Zeb, S. Ahmad, H. Ullah, and Z. Khan, "Towards Sweetness Classification of Orange Cultivars Using Short-Wave NIR Spectroscopy," *Scientific Reports*, vol. 13, p. 262, 2023. doi: 10.1038/s41598-022-27297-2.
- [15] P. Wang, E. Fan, and P. Wang, "Comparative Analysis of Image Classification Algorithms Based on Traditional Machine Learning and Deep Learning," *Pattern Recognition Letters*, vol. 141, pp. 61–67, 2021. doi: 10.1016/j.patrec.2021.07.007.
- [16] S. Faisal, "Klasifikasi Jenis Buah Tomat Menggunakan Algoritma K-Nearest Neighbor dan Support Vector Machine," *JINTEKS*, vol. 7, no. 2, pp. 800–807, 2025. doi: 10.51401/jinteks.v7i2.5743.
- [17] J. C. Lapendy, A. A. C. Resky, H. Makmur, A. B. Kaswar, D. D. Andayani, and F. Adiba, "Klasifikasi Rasa Jeruk Siam Berdasarkan Warna dan Tekstur Berbasis Pengolahan Citra Digital," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 2, pp. 756–767, 2024. doi: 10.29100/jipi.v9i2.5384.