

Klasifikasi Kualitas Melon Inthanon Berbasis Analisis Tekstur dan Warna Menggunakan GLCM dan SVM

1st Moch. Andi Divangga Pratama
Informatika, Fakultas Direktorat
Kampus Surabaya
Universitas Telkom
Surabaya, Indonesia
andipratama@student.telkomuniversity.
ac.id

2nd Ahmad Wali Satria Bahari Johan
Informatika, Fakultas Direktorat
Kampus Surabaya
Universitas Telkom
Surabaya, Indonesia
ahmadsatria@telkomuniversity.ac.id

3rd Helmy Widyantara
Teknologi Informasi, Fakultas
Direktorat Kampus Surabaya
Universitas Telkom
Surabaya, Indonesia
helmywidyantara@telkomuniversity.ac.
id

Abstrak — Proses grading melon secara manual seringkali tidak konsisten, memakan waktu lama, dan meningkatkan biaya tenaga kerja, sehingga mengurangi efisiensi pascapanen. Penelitian ini bertujuan mengembangkan sistem grading otomatis untuk mengklasifikasikan kualitas melon Inthanon berbasis analisis tekstur dan warna. Analisis tekstur menggunakan Gray Level Co-occurrence Matrix (GLCM) untuk mengekstrak tujuh fitur utama, sedangkan analisis warna menggunakan ruang warna CIELab (a^* dan b^* channel) dengan tambahan parameter Hue dan Chroma. Dataset terdiri dari 300 citra melon dengan akuisisi gambar dilakukan dalam perlakuan terkendali. Dataset Melon Inthanon kualitas buruk dan baik di augmentasi sebanyak 14 sudut untuk data training model augmentasi. Proses klasifikasi dilakukan dalam dua tahap menggunakan Support Vector Machine (SVM), yaitu untuk klasifikasi jenis melon (Net/Non-Net) kemudian kualitas melon (Baik/Buruk). Fitur warna dan tekstur terbukti akurat dan efisien dalam mengklasifikasikan kualitas Melon Inthanon dengan hasil akurasi pada model klasifikasi jenis melon tanpa augmentasi sebesar 100%, model klasifikasi kualitas inthanon tanpa augmentasi sebesar 95%, dan model augmentasi mendapatkan akurasi lebih rendah dari model tanpa augmentasi yaitu sebesar 87.5%. Temuan ini menunjukkan efektivitas metode yang diusulkan dan mengotomatisasikan klasifikasi kualitas Melon Inthanon.

Kata kunci— CIELab, GLCM, Grading Otomatis, Melon Inthanon, SVM

I. PENDAHULUAN

Melon (*Cucumis melo* L.) merupakan buah populer di Indonesia, khususnya di Jawa Timur, karena rasanya yang manis, kesegaran, dan manfaat kesehatan seperti kandungan vitamin A, vitamin C, serta mineral yang tinggi [1]. Salah satu varietas melon bertekstur adalah melon Inthanon yang dikenal memiliki tekstur kulit khas berupa pola retikulasi [2]. Proses penilaian kualitas melon pascapanen umumnya masih dilakukan secara manual, yang memakan waktu lama, rentan terhadap inkonsistensi, dan meningkatkan biaya tenaga kerja, sehingga menurunkan efisiensi proses pascapanen [1], [3]. Studi sebelumnya menunjukkan bahwa grading manual

memiliki tingkat kesalahan lebih tinggi dibandingkan grading otomatis, yang mampu menurunkan tingkat kesalahan hingga 11,8% [4], [5].

Parameter utama untuk grading kualitas melon secara otomatis adalah tekstur dan warna kulit buah. Tekstur kulit, terutama pola retikulasi, menunjukkan lignifikasi optimal yang berhubungan dengan kekuatan mekanis buah [6]. Perubahan warna kulit dari hijau ke kuning mengindikasikan kematangan dan kualitas internal seperti kandungan karotenoid serta tingkat kemanisan [7]. Penelitian sebelumnya mengonfirmasi keefektifan metode *Gray Level Co-occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM) dalam grading otomatis berbagai buah seperti apel, delima, mangga, dan kelapa dengan akurasi yang tinggi [8], [9], [10], [11]. Namun, penelitian terkait grading otomatis melon khususnya varietas ber-net seperti melon Inthanon masih sangat terbatas.

Oleh karena itu, penelitian ini bertujuan mengembangkan sistem grading otomatis berbasis analisis tekstur dan warna menggunakan kombinasi metode GLCM untuk ekstraksi fitur tekstur, ruang warna CIELab dengan tambahan Hue dan Chroma untuk ekstraksi fitur warna, serta SVM sebagai algoritma klasifikasi. Penelitian ini secara spesifik bertujuan untuk mengembangkan model grading otomatis melon ber-net varietas Inthanon dan mengukur akurasi algoritma SVM dalam mengklasifikasikan jenis serta kualitas melon secara efisien dan akurat. Diharapkan hasil penelitian ini mampu berkontribusi terhadap pengembangan teknologi grading otomatis di sektor agribisnis.

II. KAJIAN TEORI

A. Melon Inthanon



GAMBAR 1 (A) Melon Inthanon

Melon Inthanon merupakan varietas melon ber-net yang memiliki tekstur kulit khas berupa pola retikulasi atau jala,

terbentuk melalui proses suberisasi saat pematangan seperti pada GAMBAR 1 (A). Pola ini memberikan perlindungan mekanis terhadap keretakan dan kehilangan kelembaban serta menjadi indikator visual penting dalam penilaian kualitas buah. Melon ini kaya akan nutrisi seperti β -karoten, vitamin C, dan serat yang memberikan manfaat kesehatan, menjadikannya pilihan buah konsumsi unggul [2], [6].


Varietas Inthanon dipilih dalam penelitian ini karena pola tekstur kulitnya yang kompleks dan perubahan warna kulit dari hijau ke kuning selama pematangan, menjadikannya ideal untuk analisis visual otomatis berbasis tekstur dan warna. Karakteristik tersebut menghadirkan tantangan sekaligus peluang untuk inovasi teknologi grading otomatis di bidang agribisnis.

B. Pengolahan Citra

Pengolahan citra adalah proses analisis, modifikasi, dan ekstraksi informasi dari gambar digital melalui beberapa tahap, seperti akuisisi citra, praproses, segmentasi, ekstraksi fitur, dan klasifikasi. Teknik ini memungkinkan evaluasi otomatis terhadap karakteristik visual seperti tekstur dan warna, yang krusial untuk penilaian kualitas melon secara objektif dan efisien [10].

C. Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) merupakan metode statistik untuk analisis tekstur citra digital dengan mengidentifikasi hubungan spasial antar piksel berdasarkan tingkat keabuan seperti pada GAMBAR 2 (C).



GAMBAR 2 (C) Proses GLCM[12]

Metode ini menghasilkan matriks yang dinormalisasi. Matriks ini kemudian digunakan untuk mengekstraksi fitur tekstur yang menggambarkan karakteristik pola visual dari citra seperti *Corellation*, *Energy*, *Homogeneity*, *Entropy*, *Dissimilarity*, dan *Inverse Difference Moment*. Berikut adalah penjelasannya :

- *Correlation* mengukur hubungan linear antara intensitas piksel.

$$Correlation = \frac{\sum_{i,j} P(i,j) \cdot (i - \mu_i) - (j - \mu_j)}{\sigma_i \cdot \sigma_j} \quad (1)$$

- *Energy* mencerminkan uniformitas matriks GLCM. Nilai lebih tinggi menunjukkan tekstur yang lebih seragam.

$$Energy = \sum_{i,j} P(i,j)^2 \quad (2)$$

- *Homogeneity* mengukur kedekatan distribusi elemen-elemen GLCM dengan diagonal utama.

$$Homogeneity = \sum_{i,j} \frac{P(i,j)}{1 + |i - j|} \quad (3)$$

- *Entropy* mengukur kekacauan atau ketidakteraturan dalam matriks GLCM.

$$Entropy = - \sum_{i,j} P(i,j) \cdot \log(P(i,j)) \quad (4)$$

- *Dissimilarity* memberikan bobot lebih kecil pada pasangan piksel dengan yang lebih dekat.


$$Dissimilarity = \sum_{i,j} P(i,j) \cdot |i - j| \quad (5)$$

- *Inverse Difference Moment* mengukur homogenitas tekstur, dengan penekanan lebih besar pada pasangan piksel dengan nilai intensitas yang serupa.

$$IDM = \sum_{i,j} \frac{P(i,j)}{1 + (i - j)^2} \quad (6)$$

D. CIELab

Ruang warna CIELab dikembangkan oleh CIE untuk merepresentasikan persepsi warna manusia secara akurat.



GAMBAR 3 (D) Ilustrasi ruang warna CIELab

Seperti yang terdapat pada GAMBAR 3 (D) komponennya meliputi L^* (kecerahan), a^* (transisi hijau–merah), dan b^* (biru–kuning), yang sangat sensitif terhadap perubahan warna selama pematangan buah. Konversi dari RGB ke CIELab dilakukan melalui transformasi ke ruang XYZ terlebih dahulu menggunakan persamaan 7.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4124564 & 0.3575761 & 0.1804375 \\ 0.2126729 & 0.7151522 & 0.0721750 \\ 0.0193339 & 0.1191920 & 0.9503041 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (7)$$

lalu dihitung nilai L^* , a^* , dan b^* menggunakan persamaan 8, 9, dan 10.

$$L^* = 116 \cdot f\left(\frac{Y}{Y_n}\right) - 16 \quad (8)$$

$$a^* = 500 \cdot \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (9)$$

$$b^* = 500 \cdot \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (10)$$

Tambahan parameter Hue dan Chroma dihitung dari nilai a^* dan b^* menggunakan persamaan 11 dan 12.

$$Chroma = \sqrt{(a^*)^2 + (b^*)^2} \quad (11)$$

$$Hue = \begin{cases} \tan^{-1}\left(\frac{b^*}{a^*}\right), & \text{jika } a^* > 0 \text{ dan } b^* \geq 0 \\ 180 + \tan^{-1}\left(\frac{b^*}{a^*}\right), & \text{jika } a^* < 0 \end{cases} \quad (12)$$

untuk memperkaya deskripsi warna. Kombinasi komponen ini mampu mengidentifikasi perubahan warna halus yang berkorelasi dengan tingkat kematangan buah [13].

E. Otsu Thresholding

Otsu Thresholding adalah metode segmentasi citra biner yang secara otomatis menentukan ambang optimal dengan memaksimalkan varians antar-kelas (*between-class variance*) menggunakan persamaan 13 dan 14. Teknik ini bekerja dengan menganalisis histogram citra untuk mencari nilai ambang yang memisahkan dua kelas piksel, yaitu objek dan latar belakang, dengan error klasifikasi minimum

$$\sigma_B^2(k) = \frac{(m_G P_1(k) - m(k))^2}{P_1(k)(1 - P_1(k))} \quad (13)$$

$$\sigma_B^2(k^*) = \max_{0 \leq k \leq L-1} \sigma_B^2(k) \quad (14)$$

Di mana:

- m_G adalah rata-rata global
- $P_1(k)$ adalah probabilitas kelas pertama
- $m(k)$ adalah rata-rata kumulatif hingga level k

Metode ini sangat efektif pada citra dengan histogram bimodal dan tidak memerlukan intervensi manual, menjadikannya ideal untuk aplikasi pengolahan citra otomatis [14].

F. Dilasi

Dilasi adalah salah satu operasi dasar dalam pemrosesan citra morfologi yang digunakan untuk memperbesar objek *foreground* dalam citra biner. Dilasi bekerja dengan menambahkan piksel pada tepi objek berdasarkan elemen struktur yang ditentukan sebelumnya. Secara matematis, dilasi dirumuskan sebagai:

$$A \oplus B = \{z | (B)_z \cap A \neq \emptyset\} \quad (15)$$

di mana A adalah citra input, B adalah elemen struktur, dan z adalah posisi pergeseran. Dilasi sering digunakan untuk memperbesar struktur *foreground* atau menghubungkan komponen terputus [15].

G. Erosi

Erosi adalah operasi morfologi yang bertujuan untuk mengurangi ukuran objek *foreground* dalam citra biner. Erosi bekerja dengan menghapus piksel di tepi objek, sehingga ukuran objek menjadi lebih kecil. Secara matematis, dilasi dirumuskan sebagai:

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (16)$$

di mana A adalah citra input, B adalah elemen struktur, dan z adalah posisi pergeseran. Erosi sering digunakan untuk menghapus *noise* atau memperkecil area *foreground* dalam citra biner [15].

H. Support Vector Machine

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin untuk klasifikasi dan regresi, yang bekerja dengan menemukan *hyperplane* optimal untuk memisahkan data ke dalam kelas dengan margin maksimum. Titik data terdekat dengan *hyperplane* disebut *support vectors* [16].

Untuk data yang dapat dipisahkan secara linear, SVM mencari *hyperplane* dengan fungsi keputusan:

$$f(x) = w^T x + b \quad (17)$$

dengan minimisasi norma kuadrat vektor bobot:

$$\min \frac{1}{2} \|w\|^2 \quad (18)$$

dan kendala margin:

$$y_i(w^T x_i + b) \geq 1 \quad (19)$$

di mana (y_i) adalah label kelas (+1 atau -1), (x_i) adalah titik data, dan (w) adalah vektor bobot. SVM linear efisien untuk data berukuran besar [17].

Untuk data non-linear, SVM menggunakan fungsi kernel untuk memetakan data ke ruang dimensi lebih tinggi:

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (20)$$

Jenis *kernel* meliputi linear, polynomial, RBF, dan sigmoid, dengan parameter seperti *Gamma* dan penalti (C) untuk mengontrol kompleksitas [18].

I. Confusion Matrix

Confusion matrix adalah alat evaluasi performa model klasifikasi yang membandingkan prediksi dengan kelas sebenarnya, terdiri dari empat komponen: *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN).

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN


GAMBAR 4 (I) Confusion Matrix

Matriks ini menghitung akurasi sebagai rasio prediksi benar (TP + TN) terhadap total data:

$$Accuracy = \frac{TN + TP}{TP + FP + TN + FN} \quad (21)$$

Melalui confusion matrix, kinerja model dievaluasi secara kuantitatif, termasuk identifikasi kesalahan klasifikasi [14].

III. METODE



GAMBAR 5 Blok diagram sistematika penyelesaian masalah

GAMBAR 5 menggambarkan sistematika penyelesaian masalah penelitian, dimulai dari akuisisi citra, labeling data, dan pemisahan menjadi data latih (80%) serta data uji (20%). Terdapat tiga model yang dibangun dan diuji: (1) klasifikasi jenis melon (net atau non-net) menggunakan fitur tekstur saja; (2) klasifikasi kualitas Melon Inthanon (baik atau buruk) tanpa augmentasi; dan (3) klasifikasi kualitas dengan augmentasi rotasi (14 sudut) untuk membandingkan performa. Jika augmentasi diterapkan, citra asli dirotasi terlebih dahulu sebelum *preprocessing*; jika tidak, langsung ke tahap *preprocessing*.

Preprocessing citra meliputi resize ke 420×420 piksel, konversi ke ruang warna CIE Lab, Gaussian Blur pada kanal b^* , Otsu thresholding, operasi morfologi opening dan closing, pemilihan kontur terbesar menggunakan fungsi max contour dari OpenCV untuk membentuk mask biner, serta penerapan mask pada citra RGB untuk menghasilkan citra tersegmentasi.

Setelah segmentasi, citra di-crop menggunakan bounding rect dari OpenCV untuk menghilangkan area hitam. Citra crop dikonversi ke CIE Lab untuk mendapatkan kanal a^* dan b^* , diikuti kalkulasi Hue dan Chroma. Selanjutnya, binary thresholding dengan ambang 10 dilakukan untuk masking data fitur warna (hanya piksel dengan nilai 255 pada mask), diikuti ekstraksi statistik mean dan standar deviasi, menghasilkan 8 fitur warna. Untuk tekstur, citra diubah ke grayscale, lalu diekstrak menggunakan GLCM pada empat sudut (0° , 45° , 90° , 135°) dengan jarak 1, menghasilkan 24 fitur (mean, standar deviasi, maksimum, minimum per properti GLCM).

Pelatihan model menggunakan dua skenario: (1) hyperparameter terbaik dari grid search dengan k-fold cross validation; dan (2) *tuning* manual hyperparameter SVM. Setelah pelatihan, *hyperplane* diuji pada data tes, diikuti evaluasi berdasarkan akurasi dan waktu inferensi.

A. Akuisi Citra


Tahapan pertama penelitian adalah akuisisi data citra buah melon dari dua jenis: net (Inthanon) dan non-net (Golden Langkawi), bersumber dari Green House UPT Pengembangan Agribisnis Tanaman Pangan dan Hortikultura Provinsi Jawa Timur. Citra diambil menggunakan kamera ponsel mode manual (pro) dengan pengaturan white balance, ISO, dan shutter speed konstan, latar belakang hitam (kertas) untuk fokus pada melon, serta pencahayaan difus untuk meminimalkan bayangan dan variasi warna. Jumlah data: 100 citra Golden Langkawi (non-net), 100 Inthanon berkualitas baik (net), dan 100 Inthanon berkualitas buruk (net), dengan format RGB dan resolusi minimum 1920×1080 piksel. Pelabelan dilakukan secara manual dengan bantuan UPT untuk menjaga preferensi kualitas.

B. Augmentasi

Augmentasi dilakukan untuk meningkatkan jumlah data latih, mengurangi overfitting, dan mensimulasikan posisi melon di conveyor. Hanya diterapkan pada dua kelas Melon Inthanon (baik dan buruk) melalui rotasi citra dengan 14 sudut: 6° , -6° , 20° , -20° , 34° , -34° , 48° , -48° , 62° , -62° , 76° , -76° , 90° , dan -90° . Teknik ini menghasilkan variasi tampilan tanpa mengubah karakteristik tekstur atau warna, karena mensimulasikan kondisi terkontrol tanpa perbedaan intensitas cahaya. Hasilnya, total data per kelas mencapai 1500 citra, memperkaya representasi fitur dan meningkatkan generalisasi model.

C. Pra-proses Citra

Sebelum ekstraksi fitur, dilakukan pra-proses citra untuk memastikan hanya area melon yang diolah, tanpa objek sekitarnya.



GAMBAR 6 (C) Diagram alir pra-proses citra

Sesuai dengan GAMBAR 6 (C) langkah pertama adalah resize citra ke 420×420 piksel menggunakan interpolasi bilinear untuk menyamakan skala dan mengurangi beban komputasi. Selanjutnya, konversi dari RGB ke CIE Lab untuk representasi warna akurat, dengan komponen L^* (kecerahan) [Persamaan II.10], a^* (hijau-merah) [Persamaan II.11], dan b^* (biru-kuning) [Persamaan II.12], berdasarkan nilai tristimulus X, Y, Z. Gaussian Blur diterapkan untuk menghaluskan citra dan mengurangi noise, diikuti Otsu thresholding pada kanal b^* untuk pemisahan optimal berdasarkan varians intra-kelas. Hasil dimurnikan dengan morfologi opening (erosi lalu dilasi) dan closing (dilasi lalu erosi) menggunakan kernel persegi 5×5 . Kontur terbesar dipilih dengan fungsi Contours dari OpenCV untuk membentuk mask biner, yang kemudian diaplikasikan pada citra RGB untuk menghasilkan citra tersegmentasi dengan latar belakang hitam.


D. Ekstraksi Warna

Setelah segmentasi, citra di-crop menggunakan bounding rect dari OpenCV untuk menghilangkan area hitam. Selanjutnya, dilakukan binary thresholding (ambang 10) untuk mendapatkan mask dari citra crop. Citra RGB hasil crop dikonversi ke ruang warna CIELab untuk mengambil nilai a^* dan b^* , lalu dihitung fitur tambahan Hue dan Chroma menggunakan Persamaan 11 (Chroma) dan 12 (Hue). Masking diterapkan agar hanya fitur warna pada area melon yang dianalisis, dengan mencocokkan koordinat mask dan data fitur warna tiap piksel. Terakhir, dihitung statistik mean dan standar deviasi untuk setiap fitur warna pada area objek.

E. Ekstraksi Tekstur

Ekstraksi fitur tekstur menggunakan GLCM [Gambar II.2] dilakukan dengan menghitung matriks ko-occurrence pada empat arah (0° , 45° , 90° , 135°) dan jarak tertentu. Dari matriks ini diekstrak enam fitur utama: Correlation, Energy, Homogeneity, Entropy, Dissimilarity, dan Inverse Difference Moment (IDM). Setiap fitur dihitung statistiknya (mean, standar deviasi, maksimum, minimum) untuk menghasilkan representasi global yang konsisten, yang selanjutnya digunakan dalam analisis atau klasifikasi.

F. Klasifikasi Jenis Melon Menggunakan SVM



GAMBAR 7 (F) Diagram alir *Support Vector Machine*

Pada GAMBAR 7 (F) klasifikasi jenis melon dengan SVM dimulai dengan membagi data menjadi latih (80%) dan uji (20%). Fitur yang digunakan adalah hasil ekstraksi tekstur GLCM dari citra grayscale Gambar 6 (F). Validasi model dan optimasi hyperparameter dilakukan menggunakan Stratified K-Fold Cross Validation (5 fold) serta Grid Search untuk mencari kombinasi kernel dan parameter terbaik (C, gamma). Hasil optimasi dibandingkan juga dengan pencarian manual hyperparameter.

Model SVM kemudian dilatih menggunakan seluruh data latih dan parameter optimal, membentuk hyperplane yang memisahkan kelas net dan non-net. Pada tahap pengujian, data uji diprediksi menggunakan model yang telah dilatih, menghasilkan klasifikasi jenis melon berdasarkan fitur tekstur. Proses validasi dan optimasi ini memastikan model akurat dan mampu melakukan generalisasi pada data baru.

G. Klasifikasi Kualitas Melon

Setelah fitur warna (a^* , b^* , Hue, Chroma) dan tekstur (Correlation, Energy, Homogeneity, Entropy, Dissimilarity, IDM) diekstraksi, keduanya digabungkan menjadi satu vektor fitur untuk analisis klasifikasi kualitas Melon Inthanon yang lebih komprehensif. Dataset dibagi menjadi data latih (80%) dan uji (20%), lalu model SVM dilatih menggunakan gabungan fitur tersebut Gambar 6 (F).

Validasi dan optimasi hyperparameter dilakukan secara bersamaan menggunakan Stratified K-Fold Cross Validation (5 fold) dan Grid Search untuk mencari kombinasi kernel dan parameter terbaik (C, gamma). Hasil optimasi juga dibandingkan dengan pencarian manual hyperparameter. Model SVM kemudian dilatih ulang dengan seluruh data latih dan parameter optimal, membangun hyperplane yang memisahkan kelas kualitas baik dan buruk.

Pada tahap pengujian, data uji dimasukkan ke model SVM untuk prediksi kelas kualitas melon berdasarkan posisi fitur dalam ruang hyperplane. Gabungan fitur warna dan tekstur ini memastikan klasifikasi kualitas melon yang lebih akurat dan robust.

IV. HASIL DAN PEMBAHASAN

A. Akuisisi Citra

Tabel 1 (A) *Sample* citra melon

		
Melon Jenis Inthanon Kualitas Baik	Melon Jenis Inthanon Kualitas Buruk	Melon Jenis Golden Langkawi

Sebanyak 300 foto melon diambil dari tiga kebun yaitu Kebun Sanjaya Hidroponik berlokasi di Kabupaten Kediri, Kebun Kagi Farm berlokasi di Kabupaten Gresik, dan Kebun UPT Pengembangan Agribisnis Tanaman Pangan dan Hortikultura Provinsi Jawa Timur berlokasi di Kabupaten Sidoarjo, terdiri dari 100 foto Golden Langkawi, 100 Inthanon berkualitas baik, dan 100 Inthanon berkualitas buruk. Pengambilan gambar menggunakan kertas putih sebagai latar untuk meminimalkan gangguan background, dengan ISO kamera diatur ke 100. Melon Inthanon berkualitas baik tampak emas cerah dan net rapat, sedangkan yang buruk berwarna kuning kehijauan dengan net tidak beraturan; Golden Langkawi berwarna kuning keemasan tanpa net. Sebelum ekstraksi fitur, citra diproses untuk memisahkan buah dari latar belakang.

B. Augmentasi Citra

Dataset augmentasi dibuat untuk membandingkan performa model klasifikasi kualitas melon Inthanon. Augmentasi dilakukan dengan merotasi citra pada 14 sudut (6° , -6° , 20° , -20° , 34° , -34° , 48° , -48° , 62° , -62° , 76° , -76° , 90° , -90°), sehingga setiap kelas menghasilkan 1200 data (14 rotasi + 1 asli $\times$ 80 citra train). Rotasi ini mensimulasikan variasi posisi buah di conveyor. Untuk keterlacakan, citra augmentasi diberi suffix sesuai sudut rotasi (misal:


_segmented_rot6), sedangkan citra asli diberi suffix _segmented_base.

Tabel 2 (G) *Sample* citra augmentasi

Nama File	Citra
IMG_20250220_111444_base	
IMG_20250220_111444_rot6	
IMG_20250220_111444_rot-6	
IMG_20250220_111444_rot20	
IMG_20250220_111444_rot-20	
IMG_20250220_111444_rot34	
IMG_20250220_111444_rot-34	
IMG_20250220_111444_rot48	
IMG_20250220_111444_rot-48	
IMG_20250220_111444_rot62	
IMG_20250220_111444_rot-62	
IMG_20250220_111444_rot76	
IMG_20250220_111444_rot-76	
IMG_20250220_111444_rot90	
IMG_20250220_111444_rot-90	

C. Pra-proses Citra

Setelah input citra, gambar di-resize menjadi 420×420 piksel menggunakan OpenCV untuk menjaga detail pola kulit melon dan efisiensi batch. Citra kemudian dikonversi ke ruang warna CIELAB, memanfaatkan kanal b* yang memberikan kontras terbaik antara kulit melon dan latar. Gaussian Blur 7×7 diterapkan untuk mengurangi noise sebelum thresholding Otsu, yang secara otomatis memisahkan area buah dan latar menjadi citra biner. Mask biner dibersihkan dengan morfologi opening (kernel 1×1) dan closing (kernel 3×3) untuk menghilangkan noise dan menutup lubang kecil. Kontur terbesar dipilih sebagai area buah, lalu mask final diaplikasikan ke citra berwarna sehingga latar menjadi hitam dan area buah tetap utuh. Ilustrasinya dapat dilihat pada GAMBAR 8 (C).



GAMBAR 8 (C) Ilustrasi *preprocessing* citra

D. Ekstraksi Fitur

Ekstraksi fitur dilakukan pada dua domain: warna dan tekstur. Area buah dipotong dengan bounding box, lalu dikonversi ke CIELAB untuk mengambil kanal a dan b. Dari sini dihitung rata-rata dan simpangan baku, serta dua deskriptor turunan, Hue dan Chroma, sehingga total ada 8 fitur warna (masing-masing mean dan std). Perhitungan hanya pada piksel mask untuk menghindari latar.

Untuk tekstur, citra diubah ke grayscale dan latar diset nol, lalu GLCM dihitung pada empat orientasi (0°, 45°, 90°, 135°). Dari GLCM diekstrak enam properti (correlation, energy, homogeneity, dissimilarity, entropy, IDM), masing-masing direkap dengan mean, std, max, dan min, menghasilkan 24 fitur tekstur. Gabungan 8 fitur warna dan 24 fitur tekstur membentuk vektor fitur tiap sampel. Untuk klasifikasi jenis melon hanya digunakan fitur tekstur, sedangkan untuk kualitas melon digunakan gabungan fitur warna dan tekstur.

Tabel 3 *Sample* hasil ekstraksi fitur

Nama fitur	Melon Jenis Inthanon Kualitas Baik	Melon Jenis Inthanon Kualitas Buruk	Melon Jenis Golden Langkawi
a mean	11,29109	-4,161355	-
a std	3,25289	2,3109	-

Nama fitur	Melon Jenis Inthanon Kualitas Baik	Melon Jenis Inthanon Kualitas Buruk	Melon Jenis Golden Langkawi
b_mean	40,937237	42,423023	-
b_std	9,10295	6,577703	-
Hue_mean	74,2365	95,64868	-
Hue_std	4,609104	3,40488	-
Chroma_mean	42,59392	42,6943	-
Chroma_std	9,08564	6,544688	-
correlation_mean	0,959032	0,985631	0,986919
correlation_std	0,008269	0,002547	0,002045
correlation_max	0,972516	0,988447	0,989759
correlation_min	0,95216	0,981624	0,984704
energy_mean	0,223282	0,191708	0,2127
energy_std	0,002143	0,001447	0,001386
energy_max	0,226411	0,193673	0,214289
energy_min	0,221277	0,18999	0,211288
homogeneity_mean	0,310162	0,364735	0,434832
homogeneity_std	0,013735	0,00888	0,010323
homogeneity_max	0,332677	0,374288	0,446921
homogeneity_min	0,29844	0,355219	0,424241
dissimilarity_mean	9,448403	4,633157	3,068721
dissimilarity_std	1,208983	0,355338	0,210855
dissimilarity_max	10,480155	5,081667	3,283825
dissimilarity_min	7,474314	4,246129	2,83626
entropy_mean	10,156597	10,268598	8,99213
entropy_std	0,131866	0,077917	0,051864
entropy_max	10,270862	10,353151	9,045939
entropy_min	9,941677	10,180791	8,933435
idm_mean	0,310162	0,364735	0,434832
idm_std	0,013735	0,00888	0,010323
idm_max	0,332677	0,374288	0,446921
idm_min	0,29844	0,355219	0,424241

E. Grid Search dengan K-Fold Cross Validation
Tahapan ini menggunakan stratified 5-fold cross-validation untuk memastikan evaluasi model SVM yang adil, dengan setiap lipatan mempertahankan rasio label yang sama.

Tabel 4 (E) List parameter C yang digunakan pada grid search

C_list						
0.01	0.05	0.1	0.5	1	10	100

Tabel 5 (E) List parameter gamma yang digunakan pada grid search

Gamma_list								
"scale"	"auto"	10	1	0.5	0.1	0.05	0.01	0.001

Selanjutnya, grid search dilakukan untuk mencoba 574 kombinasi hyperparameter: 7 untuk kernel linear (variasi C),

63 untuk RBF ($C \times \text{gamma}$), 378 untuk polynomial ($C \times \text{gamma} \times \text{degree} \times \text{coef0}$), dan 126 untuk sigmoid ($C \times \text{gamma} \times \text{coef0}$). Rentang parameter C (0.01–100) dan gamma ("scale", "auto", 10–0.001) dipilih agar model diuji dari regularisasi kuat hingga lemah dan dari batas keputusan sederhana hingga kompleks. Hasil akhir berupa kombinasi parameter terbaik dan akurasi rata-rata validasi. Berikut adalah hasil parameter terbaik dari setiap model yang dapat dilihat pada Tabel 6 (E), 7 (E), dan 8 (E).

Tabel 6 (E) Akurasi dan parameter terbaik hasil grid-search dengan k-fold pada model klasifikasi jenis melon

Akurasi dan Parameter terbaik		
Kernel	C	Akurasi
linear	0.1	100%

Tabel 7 (E) Akurasi dan parameter terbaik hasil grid search dengan k-fold pada model tanpa augmentasi klasifikasi kualitas melon inthanon

Akurasi dan Parameter terbaik					
Kernel	Derajat	C	Coef0	Gamma	Akurasi
polynomial	3	100	1	0.001	92.5%

Tabel 8 (E) Akurasi dan parameter terbaik hasil grid search dengan k-fold pada model augmentasi klasifikasi kualitas melon inthanon

Akurasi dan Parameter terbaik					
Kernel	Derajat	C	Coef0	Gamma	Akurasi
polynomial	3	100	1	"scale"	99.9%

F. Model Klasifikasi

Model klasifikasi menggunakan 32 fitur berdimensi tinggi, sehingga visualisasi 2D/3D tidak dapat dilakukan. SVM memproses data dengan operasi dot product antara vektor bobot dan fitur, mengintegrasikan seluruh fitur dalam satu perhitungan. Efisiensi SVM di dimensi tinggi dicapai karena hanya dot product dengan support vectors yang dihitung, sehingga kompleksitas bergantung pada jumlah support vectors, bukan jumlah fitur.

Tiga model dikembangkan: klasifikasi jenis melon (net/non-net) dan klasifikasi kualitas Melon Inthanon (baik/buruk) dengan augmentasi dan tanpa augmentasi. Proses dimulai dengan klasifikasi jenis; jika hasilnya non-net, proses berhenti, sedangkan jika net, dilanjutkan ke klasifikasi kualitas. Model yang digunakan pada klasifikasi kualitas dapat dipilih salah satu dari kedua model. Setelah dilakukan pelatihan dan pengujian terhadap model-model klasifikasi, diperoleh hasil evaluasi sebagai berikut:

Tabel 9 (F) Perbandingan akurasi test dan waktu inferensi pada hyperparameter dari grid search dan manual search

Model	Hyperparameter Grid Search + K-Fold CV	Hyperparameter Manual	Akurasi Test Grid Search + K-Fold CV	Akurasi Test Manual	Waktu Inferensi per Citra (ms)
1	kernel = "linear", C = 0.1	kernel = "linear", C = 0.05	97.5%	100%	1.2

2	kernel = "poly", degree = 3, c = 100, coef0 = 1, gamma = 0.001	kernel = "linear", C = 25	82.5%	95%	0.6
3	kernel = "poly", degree = 3, c = 100, coef0 = 1, gamma = "scale"	kernel = "linear", C = 15	87.5%	85%	0.4

Pada Tabel 9 (F) model klasifikasi jenis melon dengan kernel linear ($C = 0.1$) hasil Grid Search dan K-Fold Cross Validation mencapai akurasi uji 97,5% dan waktu inferensi rata-rata 1,2 ms per citra. Model manual dengan $C = 0.05$ bahkan mencapai akurasi sempurna 100%, menunjukkan bahwa regularisasi yang lebih kuat dapat meningkatkan generalisasi, dan data dapat dipisahkan optimal dengan hyperplane linear.

Pada klasifikasi kualitas melon Inthanon tanpa augmentasi, model kernel polynomial derajat 3 ($C = 100$, $\text{coef0} = 1$, $\text{gamma} = 0.001$) hanya mencapai akurasi 82,5% dengan waktu inferensi 0,6 ms per citra. Namun, dengan parameter manual (kernel linear, $C = 25$), akurasi meningkat signifikan menjadi 95%. Ini menandakan model non-linear tidak selalu lebih baik jika data sudah terdistribusi secara linier.

Model klasifikasi kualitas dengan augmentasi (kernel polynomial derajat 3, $\text{gamma} = \text{"scale"}$) menghasilkan akurasi 87,5% dan waktu inferensi tercepat 0,4 ms per citra. Namun, model manual dengan kernel linear ($C = 15$) justru sedikit menurunkan akurasi menjadi 85%. Hasil ini menegaskan bahwa model linear dengan tuning sederhana dapat menyaingi atau bahkan mengungguli model polynomial, terutama pada data dengan struktur linier yang jelas.

G. Website



GAMBAR 9 (G) Tampilan website prototipe klasifikasi

Tampilan website prototipe (Gambar IV.3) sederhana, terdiri dari kolom input gambar, dropdown pilihan model, dan tombol klasifikasi. Pengguna cukup mengunggah gambar (.jpg, .jpeg, .png), memilih model (base_model atau augmented_model), lalu menekan "Cek Kualitas". Hasil klasifikasi langsung ditampilkan dengan tiga kemungkinan: melon non-net, Inthanon berkualitas baik, atau Inthanon

berkualitas buruk. Prototipe ini berfungsi sebagai alat evaluasi cepat sebelum implementasi penuh di sistem IoT.

V. KESIMPULAN

Sistem grading otomatis berbasis SVM untuk klasifikasi jenis dan kualitas melon ber-net (Inthanon) berhasil dikembangkan dengan integrasi fitur warna (CIELab, Hue, Chroma) dan tekstur (GLCM) yang diolah menjadi statistik mean, max, min, dan standar deviasi. Sistem ini efektif merepresentasikan ciri visual melon dan menunjukkan performa inferensi sangat cepat, rata-rata di bawah 1,5 milidetik per citra, sehingga cocok untuk aplikasi semi real-time.

Algoritma SVM memberikan akurasi 100% untuk klasifikasi jenis melon (kernel linear, $C=0.05$) dan akurasi terbaik 87,5% untuk klasifikasi kualitas dengan model augmentasi rotasi (kernel polynomial derajat 3). Meskipun akurasi model augmentasi sedikit lebih rendah dari model linear non-augmentasi (95%), model ini unggul dalam efisiensi waktu dan kestabilan, membuktikan bahwa augmentasi rotasi dan kernel non-linear efektif untuk mengenali pola kompleks pada grading otomatis melon.

REFERENSI

- [1] R. A. Yuliawan and R. A. Firmansyah, "Prototype of Melon Fruit Quality Sorter Based on Skin Texture Using Local Binary Pattern Histogram," *Jurnal Ecotipe (Electronic, Control, Telecommunication, Information, and Power Engineering)*, vol. 10, no. 2, pp. 152–160, Oct. 2023, doi: 10.33019/jurnalecotipe.v10i2.4476.
- [2] T. T. H. Hai and P. T. Thao, "Effect of plant density and foliar fertilizer spray on growth and yield of netted melon (Cucumis melo L.) 'Inthanon RZ,'" *Hue University Journal of Science: Natural Science*, vol. 130, no. 1B, pp. 27–34, Jun. 2021, doi: 10.26459/hueunijns.v130i1b.6015.
- [3] S. Lin and X. Qi, "Development of Intelligent Agricultural Automation Based on Computer Vision," in *International Conference on Integrated Intelligence and Communication Systems, ICIICS 2023*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/ICIICS59993.2023.10421284.
- [4] M. T. K. Ameethajunaina, D. B. Ebenezer Abishek, D. V. Rajendren, S. Mohammed, and P. Sathish Kumar, "A Survey on Fresh Produce Grading Algorithms Using Machine Learning and Image Processing Techniques," in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing Ltd, Dec. 2020. doi: 10.1088/1757-899X/981/4/042084.
- [5] A. Bhargava and A. Bansal, "Fruits and vegetables quality evaluation using computer vision: A review," Mar. 01, 2021, *King Saud bin Abdulaziz University*. doi: 10.1016/j.jksuci.2018.06.002.
- [6] Y. Akiba, A. Ishibashi, M. Sato, and H. Shima, "Empirical Rule of Fruit Rind Fragmentation in Muskmelon Netting," *J Physical Soc Japan*, vol. 91, no. 10, Oct. 2022, doi: 10.7566/JPSJ.91.104801.

- [7] M. Vanoli *et al.*, “Nondestructive determination of ripening in melon fruit using timeresolved spectroscopy,” *Adv. Hort. Sci.*, vol. 37, no. 1, pp. 75–82, 2023, doi: 10.36253/ahsc13943.
- [8] A. Bhargava and A. Bansal, “Quality evaluation of Mono & bi-Colored Apples with computer vision and multispectral imaging,” *Multimed Tools Appl.*, vol. 79, no. 11–12, pp. 7857–7874, Mar. 2020, doi: 10.1007/s11042-019-08564-3.
- [9] X. Zou *et al.*, “Design of Electronic Nose Detection System for Apple Quality Grading Based on Computational Fluid Dynamics Simulation and K-Nearest Neighbor Support Vector Machine,” *Sensors*, vol. 22, no. 8, Apr. 2022, doi: 10.3390/s22082997.
- [10] Y. Gurubelli, R. Malmathanraj, and P. Palanisamy, “Texture and Colour Gradient Features for Grade analysis of Pomegranate and Mango Fruits using kernel-SVM Classifiers,” Apr. 2020, doi: 10.1109/ICACCS48705.2020.9074221.
- [11] H. T. Sukmana, S. Aripriyanto, M. S. Majid, and D. Khairani, “AI-Driven Coconut Quality Assessment Using GLCM and SVM for Automated Sorting,” in *2024 3rd International Conference on Creative Communication and Innovative Technology, ICCIT 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICCIT62134.2024.10701239.
- [12] F. Utaminingrum, A. W. S. B. Johan, I. K. Somawirata, T. K. Shih, and C. Y. Lin, “Indoor staircase detection for supporting security systems in autonomous smart wheelchairs based on deep analysis of the Co-occurrence Matrix and Binary Classification,” *Intelligent Systems with Applications*, vol. 23, Sep. 2024, doi: 10.1016/j.iswa.2024.200405.
- [13] D. S. Kim, D. U. Lee, J. H. Lim, S. Kim, and J. H. Choi, “Agreement between visual and model-based classification of tomato fruit ripening,” *Trans ASABE*, vol. 63, no. 3, pp. 667–674, 2020, doi: 10.13031/TRANS.13812.
- [14] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*. Pearson, 2018.
- [15] K. A. M. Said and A. B. Jambek, “Analysis of Image Processing Using Morphological Erosion and Dilation,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Nov. 2021. doi: 10.1088/1742-6596/2071/1/012033.
- [16] Q. Wang, “Support Vector Machine Algorithm in Machine Learning,” in *2022 IEEE International Conference on Artificial Intelligence and Computer Applications, ICAICA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 750–756. doi: 10.1109/ICAICA54878.2022.9844516.
- [17] S. N. Khan, S. U. Khan, H. Aznaoui, C. B. Şahin, and Ö. B. Dinler, “Generalization of linear and non-linear support vector machine in multiple fields: a review,” *Computer Science and Information Technologies*, vol. 4, no. 3, pp. 226–239, Nov. 2023, doi: 10.11591/csit.v4i3.pp226-239.
- [18] L. Sunitha and M. B. Raju, “Multi-class classification for large datasets with optimized SVM by non-linear kernel function,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Nov. 2021. doi: 10.1088/1742-6596/2089/1/012015.