

PEMANFAATAN METODE GLCM, PCA, DAN SVM UNTUK KLASIFIKASI MUTU WORTEL

Eilleen¹⁾ Raymond Eugenio Kent Sanjaya²⁾ Jocelyn Novia³⁾

¹⁾ Teknik Informatika Universitas Tarumanagara
Jl. Letjen S. Parman No. 1, Grogol, Jakarta Barat 11440 Indonesia
email : eilleen.535230051@stu.untar.ac.id

²⁾ Teknik Informatika Universitas Tarumanagara
Jl. Letjen S. Parman No. 1, Grogol, Jakarta Barat 11440 Indonesia
email : raymond.535230044@stu.untar.ac.id

³⁾ Teknik Informatika Universitas Tarumanagara
Jl. Letjen S. Parman No. 1, Grogol, Jakarta Barat 11440 Indonesia
email : jocelyn.535230046@stu.untar.ac.id

ABSTRAK

Kualitas wortel merupakan faktor krusial dalam industri pertanian, namun metode penilaian manual yang umum digunakan bersifat subjektif dan tidak konsisten. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi mutu wortel otomatis berbasis citra digital untuk mengatasi masalah tersebut. Metode yang digunakan mengintegrasikan Gray Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur tekstur, Principal Component Analysis (PCA) untuk reduksi dimensi, dan Support Vector Machine (SVM) dengan kernel RBF untuk klasifikasi. Sistem diuji menggunakan dataset 409 citra yang terbagi dalam tiga kelas: segar, kurang segar, dan busuk. Hasil pengujian menunjukkan sistem mencapai akurasi keseluruhan sebesar 90,54%. Model menunjukkan performa sangat baik pada kelas segar (akurasi 96,6%) dan busuk (akurasi 93,5%), namun performanya lebih rendah pada kelas kurang segar (akurasi 71,4%) yang bersifat transisi. Kombinasi metode yang diusulkan terbukti efektif dan memiliki potensi untuk diterapkan dalam sistem sortir otomatis di industri pertanian.

Key words

Klasifikasi Mutu, Wortel, GLCM, PCA, SVM

1. Pendahuluan

Wortel (*Daucus carota*) merupakan komoditas hortikultura dengan nilai gizi dan ekonomi yang tinggi, namun rentan mengalami penurunan mutu selama proses pascapanen [1], [2]. Penentuan mutu wortel, yang menjadi faktor krusial dalam rantai pasok, saat ini masih banyak dilakukan secara manual. Metode manual ini memiliki kelemahan signifikan karena bersifat subjektif, tidak konsisten, dan memakan waktu, sehingga sering kali produk berkualitas rendah lolos ke pasar dan merugikan konsumen serta produsen [3].

Perkembangan teknologi pengolahan citra digital menawarkan solusi untuk mengatasi keterbatasan tersebut melalui klasifikasi mutu otomatis. Penelitian ini mengusulkan sistem klasifikasi dengan mengintegrasikan tiga metode utama: *Gray Level Co-occurrence Matrix* (GLCM) untuk ekstraksi fitur tekstur, *Principal Component Analysis* (PCA) untuk mereduksi dimensi fitur agar lebih efisien, dan *Support Vector Machine* (SVM) sebagai algoritma klasifikasi akhir yang andal untuk data berdimensi tinggi [4], [5].

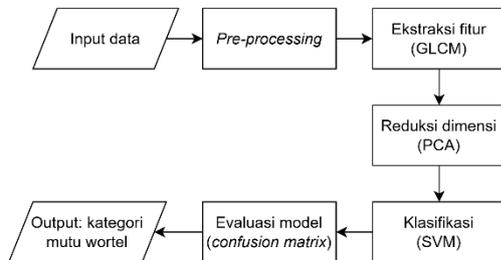
Pendekatan ini didukung oleh penelitian sebelumnya yang telah membuktikan efektivitasnya di berbagai bidang. Studi oleh Almais dkk. [6] berhasil menggunakan integrasi GLCM-PCA untuk mengklasifikasikan tingkat kerusakan bangunan pasca-bencana. Demikian pula, penelitian oleh Priyanka dan Kumar [7] menunjukkan bahwa kombinasi GLCM dan PCA mampu meningkatkan akurasi klasifikasi citra medis secara signifikan dari 53,3% menjadi 77,8%. Keberhasilan ini menunjukkan potensi besar penerapan metode serupa untuk objek biologis seperti wortel.

Meskipun efektif pada objek lain, penerapan metode GLCM-PCA-SVM secara terintegrasi untuk klasifikasi mutu wortel masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut dengan mengembangkan dan mengevaluasi sistem klasifikasi mutu wortel otomatis. Sistem ini dirancang untuk membedakan mutu wortel ke dalam kategori segar, kurang segar, dan busuk secara akurat dan konsisten. Kontribusi utama dari penelitian ini adalah menyediakan solusi teknologi yang dapat meningkatkan efisiensi dan objektivitas dalam proses penyortiran hasil pertanian, mendukung modernisasi industri agrikultur.

2. Metode Penelitian

Penelitian ini menggunakan alur kinerja sistematis yang terdiri dari beberapa tahapan utama untuk mengklasifikasikan mutu wortel berbasis citra digital.

Alur kerja, seperti yang ditunjukkan pada Gambar 1, meliputi akuisisi dan pra-pemrosesan citra, ekstraksi fitur tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM), reduksi dimensi fitur dengan *Principal Component Analysis* (PCA), proses klasifikasi menggunakan *Support Vector Machine* (SVM), dan diakhiri dengan evaluasi kinerja model.

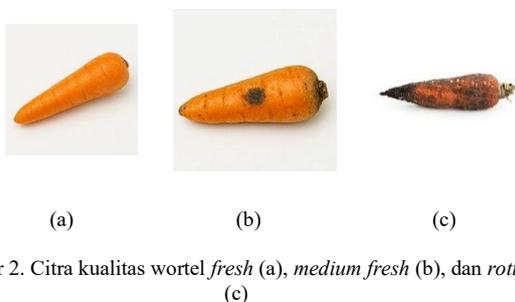


Gambar 1. Diagram alir tahapan klasifikasi mutu wortel

2.1. Akuisisi dan Pra-pemrosesan Citra

Tahap awal penelitian adalah pengumpulan data citra wortel dari dataset publik "Foodetection Dataset" yang tersedia di Kaggle. Setelah dilakukan proses pembersihan untuk menghilangkan citra buram atau terpotong, total dataset yang digunakan adalah 409 citra dalam format JPEG/PNG. Dataset ini diklasifikasikan ke dalam tiga kategori mutu, yaitu segar (*fresh*) sebanyak 163 citra, kurang segar (*medium fresh*) sebanyak 73 citra, dan busuk (*rotten*) sebanyak 173 citra. Selanjutnya, istilah *fresh*, *medium fresh*, dan *rotten* akan digunakan untuk menyebut masing-masing kategori.

Seluruh citra kemudian melalui tahap pra-pemrosesan yang meliputi beberapa langkah. Pertama, resolusi setiap gambar diseragamkan menjadi 100x100 piksel. Kedua, dilakukan segmentasi menggunakan *thresholding* pada kanal HSV untuk memisahkan objek wortel dari latar belakang. Terakhir, citra hasil segmentasi digunakan sebagai *mask* untuk menghilangkan latar belakang, sehingga hanya area wortel yang akan dianalisis. Contoh gambar dalam dataset ini ditampilkan pada Gambar 2, yang menunjukkan representasi visual dari tiga kelas kondisi mutu wortel.



Gambar 2. Citra kualitas wortel *fresh* (a), *medium fresh* (b), dan *rotten* (c)

2.2. Ekstraksi Fitur dengan GLCM

Fitur tekstur dari setiap citra wortel diekstraksi menggunakan metode GLCM. Dalam penelitian ini, matriks GLCM dibentuk dengan menggunakan empat orientasi sudut (0°, 45°, 90°, dan 135°) dengan jarak piksel (d) sebesar 1. Dari matriks yang terbentuk, dihitung enam fitur statistik untuk merepresentasikan tekstur permukaan wortel, yaitu *Contrast*, *Dissimilarity*, *Homogeneity*, *Angular Second Moment* (ASM), *Energy*, dan *Correlation* [8]. Fitur *Entropy* tidak digunakan karena kurang efektif dalam merepresentasikan karakteristik tekstur yang relevan untuk mutu wortel dan cenderung sensitif terhadap *noise* [9]. Rumus untuk menghitung masing-masing fitur ini dijelaskan sebagai berikut, dengan *levels* mewakili ukuran dari dimensi matriks, *i* mewakili indeks derajat keabuan piksel pada baris ke-*i*, *j* mewakili indeks derajat keabuan piksel pada kolom ke-*j*, dan $P_{i,j}$ mewakili nilai probabilitas pada posisi baris *i* dan kolom *j* pada GLCM [10]:

1. *Contrast*

Fitur ini mengukur variasi intensitas lokal, yang relevan untuk mendeteksi tepi tajam seperti retakan atau bercak pada permukaan wortel.

$$Contrast = \sum_{i,j=0}^{levels-1} P_{i,j} (i - j)^2 \dots(1)$$

2. *Dissimilarity*

Mirip dengan *contrast*, fitur ini mengukur seberapa tidak seragam suatu area. Nilai yang tinggi dapat mengindikasikan permukaan wortel yang tidak rata atau memiliki cacat.

$$Dissimilarity = \sum_{i,j=0}^{levels-1} P_{i,j} |i - j| \dots(2)$$

3. *Homogeneity*

Fitur ini mengukur keseragaman tekstur. Nilai homogenitas yang tinggi menunjukkan permukaan wortel yang mulus dan konsisten, yang merupakan ciri dari wortel bermutu tinggi.

$$Homogeneity = \sum_{i,j=0}^{levels-1} \frac{P_{i,j}}{1+(i-j)^2} \dots(3)$$

4. ASM (*Angular Second Moment*)

ASM mengukur konsistensi atau kekuatan pola tekstur dalam GLCM, yang mencerminkan seberapa teratur distribusi intensitas piksel pada permukaan wortel.

$$ASM = \sum_{i,j=0}^{levels-1} P_{i,j}^2 \dots(4)$$

5. *Energy*

Energy, yang merupakan akar kuadrat dari ASM, mengukur tingkat keseragaman tekstur dengan cara yang lebih halus, relevan untuk menilai konsistensi permukaan worte.

$$Energy = \sqrt{\sum_{i,j=0}^{levels-1} P_{i,j}^2} \dots(5)$$

6. Correlation

Correlation mengukur hubungan linier antara intensitas piksel berdekatan dalam GLCM, yang membantu mengidentifikasi pola tekstur teratur pada permukaan wortel.

$$Correlation = \sum_{i,j=0}^{levels-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \dots(6)$$

2.3. Reduksi Dimensi dengan PCA

Hasil ekstraksi dari fitur GLCM menghasilkan vektor fitur berdimensi tinggi. Untuk meningkatkan efisiensi komputasi, diterapkan metode PCA. PCA mentransformasikan variabel-variabel asli menjadi komponen utama (*principal components*) yang tidak berkorelasi [11]. Sebelum proses PCA, seluruh fitur dinormalisasi menggunakan *Z-Score* untuk menyetarakan skala dan memastikan tidak ada fitur yang mendominasi analisis. Proses ini mengurangi jumlah fitur yang akan digunakan dalam tahap klasifikasi tanpa kehilangan informasi yang signifikan. Tahapan algoritma PCA yang diterapkan dalam penelitian ini adalah sebagai berikut [12]:

1. Menghitung *mean* (\bar{X}) dari data pada tiap dimensi menggunakan persamaan (7)

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \dots(7)$$

Dengan:

n = jumlah data observasi

X_i = data observasi

2. Menghitung *covariance matrix* (C_x) menggunakan persamaan (8). Matriks ini mengukur sejauh mana hubungan antar variabel.

$$C_x = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \dots(8)$$

Dengan:

n = jumlah data observasi

X_i = data observasi

\bar{X} = mean

3. Menghitung *eigenvector* (v_m) dan *eigenvalue* (λ_m) dari *covariance matrix* menggunakan persamaan (9).

$$C_x v_m = \lambda_m v_m \dots(9)$$

4. Mengurutkan dan memilih *Principal Component* (komponen utama). Urutkan *eigenvalue* dengan urutan *descending*, yaitu dari yang terbesar hingga terkecil. *Principal*

Component (PC) adalah himpunan dari *eigenvector* dengan *eigenvalue* tertinggi

5. Menghasilkan dataset baru dengan data asli yang diproyeksikan ke ruang berdimensi lebih rendah menggunakan *eigenvector* yang telah dipilih.

2.4. Klasifikasi dengan SVM

Fitur yang telah direduksi dimensinya oleh PCA kemudian digunakan sebagai input untuk proses klasifikasi menggunakan algoritma SVM. SVM bertugas untuk memisahkan data ke dalam tiga kelas mutu yang telah ditentukan berdasarkan karakteristik masing-masing data. SVM bekerja dengan mencari *hyperplane* optimal yang dapat memisahkan data ke dalam tiga kelas mutu yang telah ditentukan [13]. Tujuan utama dari SVM adalah meminimalkan kesalahan klasifikasi dengan memastikan bahwa jarak antara *hyperplane* dan titik data terdekat dari masing-masing kelas (dikenal sebagai *support vectors*) adalah sejauh mungkin. Pemisahan ini menjadi semakin menantang apabila data memiliki pola distribusi yang tidak linier. Oleh karena itu, digunakan fungsi kernel untuk memetakan data ke dalam dimensi yang lebih tinggi agar data menjadi lebih mudah dipisahkan secara linear. Kernel yang digunakan dalam penelitian ini adalah *Radial Basis Function* (RBF) karena kemampuannya yang efektif dalam menangani hubungan data yang non-linear. RBF mampu memproyeksikan data ke dalam ruang fitur berdimensi tinggi, sehingga memungkinkan pemisahan yang lebih akurat antara kelas-kelas mutu yang saling tumpang tindih pada ruang aslinya. Fungsi kernel RBF secara matematis dapat dinyatakan dengan persamaan berikut:

$$K(x_i, x_j) = \exp(-\gamma ||x_i - x_j||^2) \dots(10)$$

2.5. Evaluasi Kinerja

Untuk mengukur performa model klasifikasi, digunakan *confusion matrix*. Matriks ini menyajikan perbandingan antara hasil prediksi model dengan label aktual dari data uji. Berdasarkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) dari matriks tersebut, dihitung metrik evaluasi utama sebagai berikut: [14]

1. *Accuracy*

Mengukur proporsi total prediksi yang benar terhadap seluruh data

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots(11)$$

2. *Precision*

Mengukur seberapa banyak prediksi positif yang benar

$$Precision = \frac{TP}{TP+FP} \dots(12)$$

3. Recall

Mengukur seberapa banyak data positif yang berhasil dikenali dengan benar

$$Recall = \frac{TP}{TP + FN} \dots (13)$$

4. F1-Score

Rata-rata harmonis dari presisi dan recall

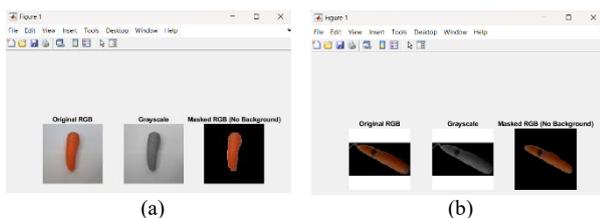
$$F1 - Score = 2x \frac{Precision \times Recall}{Precision + Recall} \dots (14)$$

3. Hasil Percobaan

Seluruh alur kerja dalam penelitian ini, mulai dari pra-pemrosesan citra, ekstraksi fitur, hingga klasifikasi, diimplementasikan menggunakan perangkat lunak MATLAB R2021a. Proses komputasi dijalankan pada perangkat dengan spesifikasi prosesor Intel Core i7, RAM 16 GB, dan sistem operasi Windows 11. Pada bagian ini, disajikan hasil dari setiap tahapan utama dalam sistem klasifikasi mutu wortel.

3.1 Hasil Pra-pemrosesan

Tahap pra-pemrosesan bertujuan untuk mengisolasi objek wortel dari latar belakang dan menyeragamkan format citra. Proses ini meliputi segmentasi berbasis ruang warna HSV dan *masking*. Dilakukan segmentasi dengan metode *thresholding* pada channel *Saturation* dan *Value* untuk memisahkan objek wortel dari latar belakang. Hasil segmentasi kemudian diperbaiki menggunakan operasi morfologi guna menghilangkan *noise* kecil agar gambar menjadi lebih bersih. Setelah proses segmentasi dan perbaikan menggunakan operasi morfologi, diperoleh citra biner berupa mask yang merepresentasikan area objek wortel. *Mask* ini kemudian digunakan untuk melakukan proses *masking*, yaitu menyeleksi dan mempertahankan objek wortel, sementara latar belakang akan dihilangkan. Sehingga hanya bagian wortel yang tersisa dan digunakan dalam proses ekstraksi fitur. Gambar 3 menunjukkan contoh hasil dari tahapan ini, di mana citra asli (*Original RGB*) berhasil diubah menjadi citra dengan latar belakang yang telah dihilangkan (*Masked RGB*) dan versi yang siap untuk ekstraksi fitur. Proses ini memastikan bahwa analisis selanjutnya hanya fokus pada area objek yang relevan.



Gambar 3. Visualisasi hasil pra-pemrosesan citra wortel: (a) *fresh*, (b) *medium fresh*

3.2 Ekstraksi Fitur

Setelah pra-pemrosesan, dilakukan ekstraksi fitur untuk merepresentasikan setiap citra secara kuantitatif. Total terdapat sembilan fitur yang diekstraksi dari setiap citra, yang terdiri dari enam fitur tekstur dari GLCM (*Contrast, Correlation, Energy, Homogeneity, ASM, Dissimilarity*) dan tiga fitur warna dari nilai rata-rata komponen HSV (*Hue, Saturation, Value*). Tabel 1 menyajikan beberapa contoh nilai fitur yang berhasil diekstraksi dari sampel citra.

Tabel 1. Beberapa Hasil Ekstraksi Fitur dari GLCM dan HSV

<i>Contrast</i>	0.4071	0.1127	0.4102	0.2136	0.3861	0.2929
<i>Dissimilarity</i>	0.3528	0.1117	0.3492	0.2128	0.3283	0.2357
<i>Homogeneity</i>	0.9455	0.8290	0.8315	0.8937	0.8416	0.8879
<i>ASM</i>	0.3682	0.1914	0.1531	0.2627	0.1368	0.2188
<i>Energy</i>	0.4364	0.7071	0.3906	0.5123	0.3692	0.4671
<i>Correlation</i>	0.7419	0.8387	0.7886	0.7669	0.8439	0.7761
<i>H_Mean</i>	224.4097	172.465	159.9886	111.6027	143.7423	165.9894
<i>S_Mean</i>	151.3443	78.5355	90.1678	62.1202	75.9988	88.8800
<i>V_Mean</i>	79.9201	46.2080	42.0194	36.7062	44.0200	31.8374
Label	"fresh"	"fresh"	"medium fresh"	"medium fresh"	"rotten"	"rotten"

3.3 Reduksi Fitur

Setelah semua fitur distandarisasi dan telah dilakukan proses PCA, dimensi data berhasil direduksi menjadi sejumlah komponen utama yang paling berkontribusi terhadap variabilitas data. Hasil dari proses ini ditampilkan pada Tabel 2, yang menyajikan nilai-nilai setiap citra dalam ruang fitur baru hasil reduksi PCA. Jumlah komponen yang dipilih disesuaikan agar mampu menjelaskan minimal 95% varians total data, sehingga informasi penting pada data tetap terjaga. Dengan transformasi ini, setiap baris pada Tabel 2 merepresentasikan citra dalam bentuk baru yang lebih ringkas namun tetap menggambarkan pola atau ciri yang relevan untuk proses klasifikasi.

Tabel 2. Hasil PCA

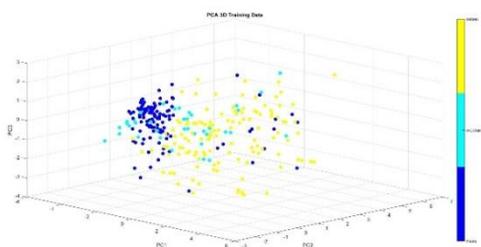
PC1	PC2	PC3	PC4	Label
-3.0083	-0.5026	0.3782	0.6192	"fresh"
-1.7230	0.0833	0.0127	0.1866	"fresh"
0.4564	2.4405	-0.4619	-1.6218	"fresh"
-2.9603	0.6402	0.5175	-0.0651	"fresh"
2.6773	3.0153	0.9111	-0.3338	"fresh"
1.2985	-2.1184	-0.3532	-0.6760	"medium fresh"
2.1431	-0.9996	0.6904	1.2250	"medium fresh"
1.2985	-2.1184	-0.3532	-0.6760	"medium fresh"
-0.0764	-0.2306	0.5813	1.0731	"medium fresh"

PC1	PC2	PC3	PC4	Label
1.7554	-0.8227	0.2713	-0.5225	"medium fresh"
0.1341	-1.0891	0.2455	-0.4831	"rotten"
3.6311	0.5022	-2.7548	-0.8619	"rotten"
3.7699	1.7533	0.7501	-0.2650	"rotten"
1.6069	-1.2937	0.9347	0.0998	"rotten"
1.0508	-1.6238	1.0298	-0.1365	"rotten"

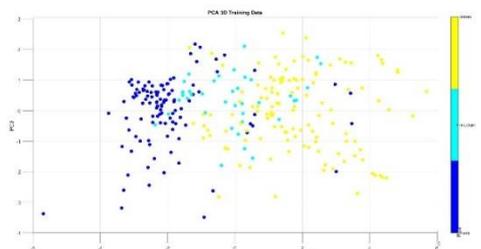
3.4 Hasil Klasifikasi

Berdasarkan hasil perhitungan *Principal Component Analysis* (PCA), jumlah komponen utama yang dipilih merupakan komponen yang secara kumulatif menjelaskan 95% total variansi data. Pemilihan ini bertujuan untuk menjaga agar proses reduksi dimensi tidak menghilangkan informasi penting yang dapat memengaruhi kinerja klasifikasi.

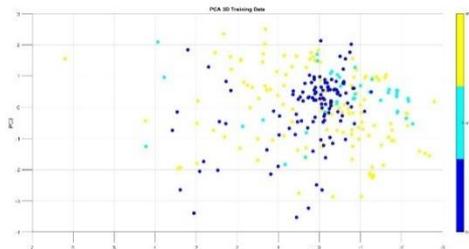
Distribusi data hasil transformasi PCA divisualisasikan dalam bentuk *plot* dua dimensi dan tiga dimensi, sebagaimana ditampilkan pada Gambar 1 dan Gambar 2. Masing-masing titik pada visualisasi *scatter plot* tersebut mempresentasikan suatu citra wortel dan diberi warna berdasarkan label kelasnya (*fresh*, *medium fresh*, atau *rotten*). Kombinasi antar komponen utama memberikan gambaran visual terkait pemisahan antar kelas berdasarkan karakteristik fitur diekstraksi.



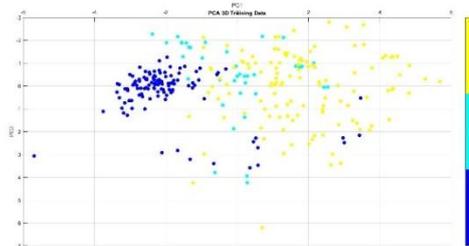
(a)



(b)

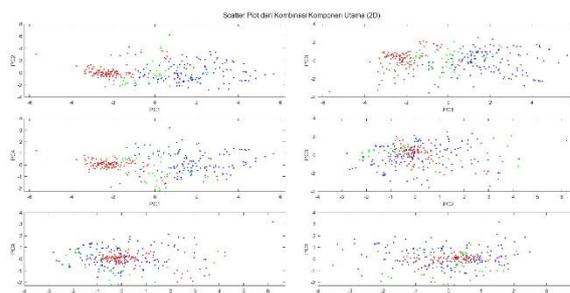


(c)



(d)

Gambar 4. Visualisasi PCA terhadap data citra wortel: *Plot* dalam ruang 3 dimensi (a), *Plot* terhadap PC3 dan PC1 (b), *Plot* terhadap PC3 dan PC2 (c), *Plot* terhadap PC1 dan PC2 (d)



Gambar 5. *Plot* dan Kombinasi Komponen Utama (2D)

Setelah pola antar kategori mulai terlihat secara visual, data hasil reduksi PCA digunakan dalam proses pelatihan dan pengujian model klasifikasi. Model yang digunakan dalam *Support Vector Machine* (SVM) berbasis kernel *Radial Basis Function* (RBF). Pipeline klasifikasi dimulai dari *pre-processing*, ekstraksi fitur (GLCM dan HSV), transformasi PCA, dan diakhiri dengan klasifikasi multikelas menggunakan SVM.

Evaluasi performa model ditunjukkan pada *confusion matrix* yang disajikan pada Tabel 3, yang menggambarkan akurasi klasifikasi untuk setiap kelas secara rinci, termasuk jumlah benar (*True Positive*) dan salah (*False Positive* dan *False Negative*). Model mampu mengklasifikasi sebagian citra dengan tepat. Dari total 74 data uji, kelas *fresh* memiliki tingkat akurasi tinggi dengan 28 dari 29 data berhasil dikenali dengan benar. Kelas *rotten* juga menunjukkan performa baik dengan 29 dari 31 data berhasil diklasifikasikan sesuai. Sementara itu, kelas *medium fresh* mengalami beberapa kesalahan klasifikasi, di mana 4 dari 14 data diklasifikasikan sebagai kelas lain. Secara umum, model mampu

membedakan ketiga kelas dengan baik, terutama setelah penerapan PCA yang berhasil mereduksi dimensi tanpa mengorbankan informasi penting dari fitur citra.

Tabel 3. Hasil Evaluasi Klasifikasi Citra Wortel Setelah PCA

Kelas	Fresh	Medium Fresh	Rotten	Total (Aktual)
Fresh	28	0	1	29
Medium	1	10	3	14
Rotten	1	1	29	31
Total	30	11	33	74

Untuk memberikan evaluasi yang lebih menyeluruh, digunakan pula metrik lain seperti akurasi keseluruhan, *precision*, *recall*, dan *F1-score*, yang divisualisasikan dalam Tabel 4.

Tabel 4. Evaluasi Keseluruhan Model Klasifikasi Wortel

Metrik	Nilai (%)
Akurasi	90,54
<i>Precision</i>	90,71
<i>Recall</i>	87,18
<i>F1-score</i>	88,51

Nilai-nilai ini menunjukkan bahwa model memiliki performa yang baik dan stabil dalam mengklasifikasi citra wortel ke dalam masing-masing kelas mutu. *Precision* yang tinggi mengindikasikan kemampuan model menangkap sebagian besar sampel yang relevan dalam setiap kelas. Namun demikian, performa model pada kelas medium masih menjadi tantangan. Hal ini dapat disebabkan oleh keterbatasan jumlah data latih dan kemiripan fitur antara kelas medium dengan dua kelas lainnya. Untuk meningkatkan akurasi klasifikasi pada kelas *medium fresh*, dapat diatasi dengan menambah jumlah data latih untuk kelas *medium fresh*, mengoptimalkan *threshold* klasifikasi, serta menambahkan fitur-fitur baru yang lebih sensitif terhadap perubahan kualitas pada kelas tersebut. Dengan perbaikan tersebut, diharapkan performa model dapat meningkat dan memberikan hasil klasifikasi yang lebih akurat di semua kelas mutu wortel.

4. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Sistem yang dikembangkan dengan mengintegrasikan metode GLCM, PCA, dan SVM berhasil mengklasifikasikan mutu wortel berbasis citra dengan performa yang baik, mencapai akurasi keseluruhan sebesar 90,54%.
2. Pendekatan yang digunakan memiliki kelebihan dalam mengidentifikasi kelas-

kelas mutu ekstrem, di mana kelas *'fresh'* dan *'rotten'* dapat diklasifikasikan dengan presisi dan *recall* di atas 93%.

3. Kelemahan utama dari sistem ini adalah performa yang lebih rendah pada kelas transisi *'medium fresh'* (kurang segar), yang disebabkan oleh karakteristik visualnya yang ambigu dan tumpang tindih dengan kelas lain.
4. Untuk pengembangan selanjutnya, disarankan beberapa perbaikan, antara lain: (1) menambah jumlah data latih, terutama untuk kelas *'medium'* agar lebih seimbang; (2) mencoba algoritma klasifikasi lain seperti *K-Nearest Neighbor* (KNN) atau *Random Forest* sebagai pembanding; dan (3) mengembangkan sistem ini menjadi implementasi praktis berbasis kamera *real-time* untuk sortir otomatis di industri.

REFERENSI

- [1] N. O. Boadi, M. Badu, N. K. Kortei, S. A. Saah, B. Annor, M. B. Bensah, H. Okyere and A. Fiebor, "Nutritional composition and antioxidant properties of three varieties of carrot (*Daucus carota*)," *Scientific African*, vol. 12, pp. 1-8, 2021.
- [2] B. N. Mirani, S. H. Chattha, S. A. Soomro, B. Wagan, I. A. Dahri, Z. A. Khan, G. Zahid and B. M. Ansari, "Effect of Post-Harvest Treatments on Quality Characteristics of Carrots During Storage," *RADS Journal of Biological Research & Applied Sciences*, vol. 13, no. 2, pp. 45-51, 2022.
- [3] A. Jahanbakhshi and K. Kheiralipour, "Evaluation of image processing technique and discriminant analysis methods in postharvest processing of carrot fruit," *Food Science & Nutrition*, vol. 8, no. 3, pp. 3346-3352, 2020.
- [4] G. Prasad, V. S. Gaddale, R. C. Kamath, V. J. Shekaranaik and S. P. Pai, "A Study of Dimensionality Reduction in GLCM Feature-Based Classification of Machined Surface Images," *Arabian Journal for Science and Engineering*, vol. 49, pp. 1531-1553, 2024.
- [5] K.-L. Du, B. Jiang, J. Lu, J. Hua and M. S. Swamy, "Exploring Kernel Machines and Support Vector Machines: Principles, Techniques, and Future Directions," *Mathematics*, vol. 12, no. 24, pp. 1-58, 2024.
- [6] A. T. W. Almais, A. Susilo, A. Naba, M. Sarosa, A. M. Juwono, C. Crysdiyan, M. A. Muslim and H. Wicaksono, "Characterization of Structural Building Damage in Post-Disaster Using GLCM-PCA Analysis Integration," *IEEE Access*, vol. 12, pp. 146190-146201, 2024.
- [7] P. and D. Kumar, "Feature Extraction and Selection of kidney Ultrasound Images Using GLCM and PCA," *Procedia Computer Science*, pp. 1722-1731, 2020.

- [8] S. A. R. Srg, M. Zarlis and W. , "Klasifikasi Citra Daun dengan GLCM (Gray Level Co-Occurence) dan K-NN (K-Nearest Neighbor)," *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, vol. 2, no. 2, pp. 477-486, 2022.
- [9] M. Abuhussein and A. Robinson, "Obscurant Segmentation in Long Wave Infrared Images Using GLCM Textures," *Journal of Imaging*, vol. 8, no. 10, 2022.
- [10] M. Yunus, "Feature Extraction : Gray Level Co-occurrence Matrix (GLCM)," Medium, 16 July 2020. [Online]. Available: <https://yunusmuhammad007.medium.com/feature-extraction-gray-level-co-occurrence-matrix-g lcm-10c45b6d46a1>. [Accessed 18 June 2025].
- [11] S. Rathod, S. Banda, N. Bandumula, A. Kumar, L. Prasanna, P. Jeyakumar, Waris Amtul, P. Muthuraman and R. M. Sundaram, *Statistical Procedures for Analyzing Agricultural Data using R*, Telangana: ICAR- Indian Institute of Rice Research, 2023.
- [12] D. Hedyati and I. M. Suartana, "Penerapan Principal Component Analysis (PCA) Untuk Reduksi Dimensi Pada Proses Clustering Data Produksi Pertanian Di Kabupaten Bojonegoro," *JIEET (Journal of Information Engineering and Educational Technology)*, vol. 5, no. 2, pp. 49-54, 2021.
- [13] S. Muthukrishnan, H. Krishnaswamy, S. Thanikodi, D. Sundaresan and V. Venkatraman, "Support Vector Machine for Modelling and Simulation of Heat Exchangers," *Thermal Science*, vol. 24, pp. 499-503, 2020.
- [14] S. Swaminathan and B. R. Tantri, "Confusion Matrix-Based Performance Evaluation Metric," *African Journal of Biomedical Research*, vol. 27, pp. 4023-4031, 2024.