



Komparasi ANN dan KNN untuk Klasifikasi Kualitas Tomat Berdasarkan HSV dan GLCM

Ilham Syihabudin, Pangundian Siagian, Reizidan Kharisma, Frans Christiopan Hutapea, Chaerur Rozikin
Program Studi Informatika, Universitas Singaperbangsa Karawang

2310631170158@student.unsika.ac.id, 2310631170038@student.unsika.ac.id, 2310631170044@student.unsika.ac.id,
2310631170086@student.unsika.ac.id, chaerur.rozikin@staff.unsika.ac.id

Abstrak

Penelitian ini bertujuan membandingkan kinerja algoritma Artificial Neural Network (ANN) dan K-Nearest Neighbors (KNN) dalam mengklasifikasikan kualitas tomat menjadi empat kategori, yaitu mentah, matang, tua, dan rusak. Tahap prapemrosesan menggunakan metode GrabCut dengan algoritma Largest Contour sebagai fallback guna mengisolasi objek dari latar belakang secara akurat. Proses ekstraksi fitur menggabungkan parameter ruang warna Hue, Saturation, Value (HSV) dan analisis tekstur Gray-Level Co-occurrence Matrix (GLCM) invarian rotasi dari empat sudut orientasi. Kombinasi kedua domain tersebut menghasilkan sepuluh fitur utama yang selanjutnya dinormalisasi menggunakan Z-Score dan diseimbangkan melalui metode Synthetic Minority Over-sampling Technique (SMOTE) guna mencegah bias terhadap kelas mayoritas. Dataset yang digunakan bersumber dari IEEE MBL-CLS (Kaggle) dan terdiri dari 7.226 citra tomat yang terbagi ke dalam empat kelas kualitas dengan distribusi yang tidak merata. Berdasarkan pengujian yang dilakukan, model ANN menunjukkan keunggulan dengan tingkat akurasi mencapai 89,63% pada konfigurasi 128 neuron, pembagian data latih dan uji 80:20, serta dropout 20%. Di sisi lain, model KNN dengan nilai ketetanggaan $K=1$ mencapai akurasi 88,10% menggunakan metrik jarak Euclidean. Analisis confusion matrix mengungkapkan bahwa kedua model mengalami kesulitan dalam memisahkan kelas tomat rusak dari kelas tomat tua akibat kemiripan profil fitur visual dan tekstur. Kinerja ini menegaskan bahwa optimalisasi hyperparameter pada pendekatan jaringan saraf tiruan mampu memberikan kapabilitas pemetaan fitur nonlinier yang lebih tinggi dibandingkan algoritma berbasis jarak untuk klasifikasi citra multikelas pada industri pertanian.

Kata kunci: Tomat, Klasifikasi, GLCM, HSV, K-Nearest Neighbors, Artificial Neural Network.

1. Pendahuluan

Tomat merupakan komoditas hortikultura strategis dengan nilai ekonomi tinggi dan tingkat produksi yang terus meningkat [1]. Kualitas tomat pascapanen sangat bergantung pada tingkat kematangan fisiknya, yang secara tradisional masih disortir secara manual. Ketergantungan pada persepsi manusia sering memunculkan masalah inkonsistensi akibat perbedaan persepsi. Oleh karena itu, otomatisasi melalui sistem *computer vision* dan pembelajaran mesin menjadi solusi untuk mengidentifikasi mutu buah secara objektif dan terotomatisasi [2].

Penelitian terdahulu telah mengeksplorasi penggunaan *computer vision* dalam identifikasi kematangan buah. Pengklasifikasian kualitas tomat menggunakan Artificial Neural Network (ANN) dengan memanfaatkan parameter warna dan fitur kulit mampu mencapai akurasi pengujian sebesar 95,5% [1]. Studi lain membuktikan bahwa pemanfaatan ruang warna Hue, Saturation, Value (HSV) menggunakan algoritma Support Vector Machine (SVM) sangat optimal dalam mendeteksi tingkat kematangan tomat hingga menembus akurasi 100% [2]. Ketangguhan algoritma SVM ini juga terbukti relevan untuk deteksi multikelas pada komoditas pertanian lain, seperti pengenalan penyakit pada tanaman anggur [12].

Penggabungan berbagai fitur ekstraksi telah terbukti meningkatkan ketahanan sistem prediksi secara signifikan [3][4]. Kombinasi ekstraksi warna Red, Green, Blue (RGB) dan matriks korelasi Gray-Level Co-occurrence Matrix (GLCM) diperlukan untuk mendeteksi penyakit daun tomat menggunakan K-Nearest Neighbors (KNN), yang memberikan performa akurasi maksimal sebesar 90,6% [3]. Metode komputasi GLCM diakui ketangguhannya dalam mengekstrak fitur statistik tekstur beresolusi tinggi secara cepat dan efisien [7][13]. Sementara itu, algoritma KNN turut dimanfaatkan untuk menyortir tingkat kematangan buah paprika dan sukses mencapai presisi 90% pada ketetanggaan terdekat $K=5$ [4]. Pada penelitian lain berhasil mengekstrak informasi

tekstur dari GLCM dan warna dari ruang HSV untuk mengklasifikasikan kesegaran buah jeruk menggunakan metode ANN dengan hasil akurasi 86,88% [5].

Secara penggabungan parameter tekstur dan spektral mampu mengatasi masalah saturasi informasi warna pada deteksi objek [6]. Metode komputasi GLCM diakui ketangguhannya dalam mengekstrak fitur statistik tekstur beresolusi tinggi secara cepat dan efisien [7]. Walaupun demikian, berbagai studi yang berfokus pada tomat sebelumnya masih rentan terhadap gangguan piksel latar belakang serta inkonsistensi saat objek mengalami rotasi spasial.

Untuk mengatasi kesenjangan tersebut, penelitian ini merancang metodologi *praprocessing Background Removal GrabCut* yang digabungkan dengan ekstraksi fitur kebal rotasi dengan mengambil nilai rata-rata metrik GLCM dari empat sudut yang berbeda, serta memadukannya dengan parameter HSV. Lebih lanjut, penelitian ini bertujuan untuk mengkomparasikan efektivitas ekstraksi fitur gabungan tersebut pada dua jenis klasifikator yang memiliki paradigma pembelajaran berbeda, yakni algoritma prediksi berbasis jarak linier KNN dan algoritma adaptif nonlinier ANN. Evaluasi komparatif ini ditujukan untuk memberikan pedoman arsitektur paling optimal guna mengklasifikasikan kualitas tomat menjadi multikelas dengan presisi tinggi.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimental komputasional yang terdiri dari tahapan pengumpulan data, prapemrosesan (*background removal*), ekstraksi ciri (10 fitur), penyeimbangan distribusi data, dan komparasi arsitektur.

2.1. Dataset Citra

Dataset Citra tomat yang digunakan dalam penelitian ini bersumber dari dataset publik IEEE MBL-CLS (*Kaggle*) yang secara total terdiri dari 7.226 citra tomat. Dataset ini merepresentasikan empat fase kualitas tomat, yaitu Mentah/*Unripe* (tomat hijau), Matang/*Ripe* (tomat merah segar), Tua/*Old* (tomat merah gelap dengan tekstur lunak), dan Rusak/*Damaged* (tomat dengan bercak fisik/pembusukan). Dataset citra tomat pascapanen berjumlah 1.760 citra, tomat matang berjumlah 2.195 citra, tomat tua berjumlah 2.214 citra, dan tomat rusak berjumlah 1.057 citra [8].

Tabel 1. Distribusi Label pada Dataset

Hasil	Jumlah
Mentah	1.760
Matang	2.195
Tua	2.214
Rusak	1.057
Total	7.226

2.2. Prapemrosesan dan Ekstraksi Fitur

Seluruh matriks gambar pada awalnya diseragamkan resolusinya menjadi skala 128x128 piksel untuk mereduksi beban waktu komputasi [8]. Tahap isolasi objek buah tomat dari gangguan latar belakang dilakukan menggunakan segmentasi metode *GrabCut*. Terdapat anomali di mana matriks *GrabCut* mengalami kegagalan dengan rasio ekstraksi area depan di bawah ambang batas 5%, sistem dirancang untuk secara otomatis melakukan *fallback* menggunakan pendekatan algoritma *Largest Contour* yang dipadukan dengan teknik ambang *Otsu Thresholding*. Proses ini kemudian disempurnakan oleh operasi *morphological closing* untuk menutup rongga bercak [7].




Gambar 1. Hasil Background Removal

Proses ekstraksi kemudian menghasilkan total 10 fitur gabungan yang berasal dari dua domain: domain warna (6 fitur berupa rata-rata dan standar deviasi dari masing-masing kanal H, S, V) dan domain tekstur (4 fitur berupa rata-rata *Contrast*, *Correlation*, *Energy*, dan *Homogeneity* dari matriks GLCM pada 4 sudut rotasi)[2][14]. Pada domain warna, matriks citra dikonversi ke dalam ruang HSV untuk mengekstraksi nilai rata-rata dan standar deviasi matematis dari masing-masing kanal warna, sehingga memproduksi enam variabel.

Pada domain tekstur, citra dikonversi ke format keabuan untuk kemudian diproses menggunakan kalkulasi GLCM. Matriks kokurensi ini dihitung pada jarak satu piksel dari empat variasi sudut rotasi untuk menciptakan invarian rotasi. Parameter tekstur yang diekstrak meliputi metrik rata-rata kontras, korelasi, energi, dan homogenitas, yang secara agregat membentuk empat variabel pelengkap [6][11]. Berikut ringkasan ekstraksi fitur yang dilakukan dalam dua domain:

- **Domain Warna (HSV):** Citra RGB dikonversi ke ruang warna HSV. Nilai rata-rata (*mean*) dari masing-masing kanal H, S, dan V dihitung, menghasilkan 6 fitur warna.
- **Domain Tekstur (GLCM):** Proses pra-pemrosesan citra diawali dengan konversi citra tomat ke bentuk *grayscale*. Selanjutnya, pembuatan matriks kookurensi dilakukan menggunakan parameter jarak 1 piksel dan sudut 0° untuk menangkap karakteristik spasial objek. Representasi visual dari tahapan pemisahan kanal warna, kurva distribusi warna (*color moments*), hingga pembentukan matriks GLCM ini secara detail dapat dilihat pada Gambar 2.



Gambar 2. Hasil Ekstraksi Fitur Domain Tekstur

Berdasarkan proses tersebut, dilakukan ekstraksi terhadap empat metrik tekstur utama dari GLCM untuk mengetahui karakteristik fisik permukaan buah. Nilai hasil perhitungan dari metrik *Contrast*, *Correlation*, *Energy*, dan *Homogeneity* secara lengkap disajikan pada Tabel 2. Matriks ini dihitung pada jarak satu piksel dengan empat variasi sudut rotasi untuk menjamin invarian rotasi. Orde kedua yang diekstrak mencakup metrik *contrast* untuk variasi intensitas, *correlation* untuk linearitas pola, *energy* untuk keseragaman, dan *homogeneity* untuk mengukur kehalusan matriks spasial. Kombinasi ini memberikan total dimensi ruang vektor 10 matriks fitur. Secara keseluruhan, kombinasi dari empat fitur tekstur ini bersama dengan fitur warna menghasilkan total 10 fitur gabungan yang digunakan sebagai input untuk pelatihan model klasifikasi.


Tabel 2. Nilai Ekstraksi Fitur Tekstur GLCM pada Citra Tomat

Fitur	Nilai	Interpretasi
<i>Contrast</i>	391.65	Variasi intensitas piksel (mendeteksi bercak/gradasi)

<i>Correlation</i>	0.9159	Keteraturan pola tekstur linier yang sangat kuat
<i>Energy</i>	0.3835	Keseragaman tekstur permukaan yang moderat
<i>Homogeneity</i>	0.5777	Tingkat kehalusan permukaan tomat

2.3. Normalisasi Data dan SMOTE

Mengingat rentang nilai fitur warna dan tekstur memiliki skala matematis yang berbeda jauh, dilakukan proses normalisasi menggunakan *Z-Score (StandardScaler)* agar data memiliki rata-rata 0 dan standar deviasi 1. Distribusi kelas pada data latih terdeteksi mengalami ketidakseimbangan (*imbalance*). Visualisasi *imbalance* pada dataset dapat dilihat pada Gambar 3.



Gambar 3. Distribusi Kelas

Untuk mencegah bias model terhadap kelas mayoritas, diterapkan teknik *Synthetic Minority Over-sampling Technique (SMOTE)* sehingga distribusi data latih menjadi proporsional [8].

2.4. Arsitektur Model Klasifikasi

Skenario pelatihan dikonfigurasi untuk membandingkan dua pendekatan komputasi. Algoritma KNN dievaluasi menggunakan rentang pencarian ketetanggaan dan mengandalkan kalkulasi geometri ruang jarak *Euclidean*. Sementara itu, kerangka kerja algoritma ANN disimulasikan menggunakan pendekatan *Multilayer Perceptron* melalui serangkaian 12 skenario penyetelan parameter [1][8]. Skenario eksperimen ini menyilang fungsi jumlah *neuron* lapisan tersembunyi pada tingkat kepadatan 32, 64, dan 128. Jaringan pemodelan juga menguji modifikasi rasio pemotongan data untuk tahapan validasi uji dan latih dengan formasi silang 70:30 serta 80:20, yang diseimbangkan oleh lapisan regulasi pencegah *overfitting Dropout* pada besaran 20% dan 50%.

- **KNN:** Dikonfigurasi dengan parameter ketetanggaan $k = 1$ dan fungsi jarak metrik *Euclidean*.
- **ANN (Multilayer Perceptron):** Dievaluasi melalui 12 skenario yang memvariasikan jumlah *dense neuron* (32, 64, 128), rasio pembagian data (70:30 dan 80:20), serta tingkat *Dropout* (20% dan 50%) untuk mitigasi *overfitting*. *Layer input* menerima 10 *node*, diikuti *hidden layer*, dan *output layer* dengan 4 *neuron* (aktivasi *Softmax*). Model dikompilasi menggunakan *optimizer Adam* selama 60 *epochs*

Skenario	Dense Neuron	Rasio Data	Dropout	Akurasi Test	
0	11	32	80:20	20%	89.63
1	7	128	80:20	20%	89.63
2	8	128	80:20	50%	89.14
3	9	64	80:20	20%	88.80
4	2	128	70:30	50%	88.51
5	1	128	70:30	20%	88.38
6	10	64	80:20	50%	88.24
7	3	64	70:30	20%	87.55
8	4	64	70:30	50%	87.18
9	5	32	70:30	20%	87.04
10	12	32	80:20	50%	85.27
11	6	32	70:30	50%	85.01

Gambar 4. Perbandingan Konfigurasi Model ANN

Puncak performa jaringan saraf ANN berhasil memecahkan angka akurasi pengenalan uji di ambang 89.63%. Konfigurasi struktur model klasifikasi terbaik ini dihasilkan secara spesifik dari penerapan porsi pemisahan dataset validasi 80:20 dan operasionalisasi jaringan tersembunyi bermuatan 128 *neuron*. Momentum keberhasilan struktural ini berjalan selaras dengan adopsi parameter toleransi *dropout* di titik 20%, yang dapat dinilai cukup efisien dalam mengerem laju kebiasaan sistem untuk semata-mata menyalin pola latih statis. Tabel 3 merangkum ringkasan perbandingan parameter dari kedua spektrum pemodelan tersebut.

3. Hasil dan Diskusi

3.1. Kinerja Algoritma dan Komparasi Skenario

Evaluasi hasil kalkulasi mengonfirmasi bahwa gabungan ekstraksi ciri warna HSV dan dimensi tekstur GLCM merumuskan pijakan matematis. Implementasi perhitungan geometri linier *Euclidean* pada KNN menemukan batas optimum pemisahan kelas tomat pada kedalaman ketetangaan $K=1$, mencatatkan perolehan akurasi kumulatif di level 88.10%. Stabilitas model pada nilai $K=1$ ini membuktikan bahwa fusi 10 fitur ruang warna dan tekstur berhasil menciptakan klaster antarkelas yang sangat padat dan terdefinisi dengan jelas, sehingga model mampu memisahkan kelas tanpa terjebak *overfitting*. Kinerja ini mengonfirmasi temuan pada penelitian sebelumnya [7][9], namun menunjukkan pola yang berbeda dari klasifikasi kematangan paprika yang lebih stabil di $K=5$ [4], yang mengindikasikan bahwa kerapatan 10 fitur gabungan tomat ini memiliki batas overlap yang lebih sempit antar data latihnya.

Evaluasi dilakukan pada data uji, difokuskan pada tingkat akurasi model (*overall accuracy*). Model KNN dengan nilai $K=1$ memberikan akurasi maksimal sebesar 88.10%. Sementara itu, model ANN diuji pada 12 skenario dengan kombinasi *hyperparameter*. Skenario terbaik ANN mencapai akurasi 89.63%, yang dicapai menggunakan arsitektur 128 *neuron* pada *hidden layer*, rasio data 80:20, dan tingkat *Dropout* 20%

Tabel 3. Perbandingan Model Berdasarkan Konfigurasi Terbaik

Model	Akurasi	Konfigurasi Terbaik
KNN	88.10%	$K = 1$, <i>Euclidean Distance</i>
ANN	89.63%	128 <i>neuron</i> , Rasio 20:20, <i>Dropout</i> 20%


Di sisi lain, puncak kinerja jaringan ANN berhasil mendemonstrasikan keunggulan kapabilitas nonlinier dengan memecahkan presisi pengenalan di akurasi sebesar 89.63% [1][8]. Konfigurasi operasionalisasi model ANN terbaik ini lahir dari porsi alokasi silang data validasi 80:20 serta pemanfaatan jaringan tersembunyi 128 *neuron*. Optimalisasi lapisan ini didukung kuat oleh batas penerapan regularisasi dropout di level 20%. Sesuai dengan temuan pada literatur terkait, penggunaan batas dropout yang moderat (20%) terbukti sangat efektif membatasi kebiasaan jaringan neuron meniru hafalan statis (mencegah *overfitting*), sementara dropout ekstrem sebesar 50% justru cenderung merugikan dan mengurangi kapasitas memori pemahaman model secara berlebihan [8][10].

3.2. Analisis Confusion Matrix

Analisis *Confusion Matrix* dilakukan untuk membedah titik lemah prediksi (lihat Gambar 5). Tren sebaran pemetaan membuktikan bahwa *Euclidean* pada KNN beroperasi stabil untuk mengukur sampel citra berlabel matang dan tua [7]. Kendati demikian, komputasi ANN menampilkan deviasi bias yang jauh lebih tangguh dalam mengisolasi citra mentah dan matang secara presisi, memfasilitasi rekognisi spektral yang sangat responsif [1][2]. Model KNN (*Euclidean distance*) mampu memisahkan kelas “Matang” (596 prediksi benar), “Tua” (570 benar), dan “Mentah” (512 benar) dengan baik. Di sisi lain, ANN jauh lebih handal dalam mendeteksi kelas “Mentah” (343 prediksi benar) dan “Matang” (404 prediksi benar) di skenario data 80:20.

Pada prosesnya, kedua mekanisme pembelajaran mesin menemui rintangan logika matematika yang sama ketika menyortir citra kelas tomat “Rusak”. Model mendapati kebingungan klasterisasi di mana sejumlah besar prediksi keliru (puluhan titik false positive) mengatribusikan sampel tomat rusak ke dalam kategori tomat “Tua”. Fenomena misklasifikasi ini terjadi akibat tumpang tindih kedekatan fitur visual dan tekstur, di mana gradasi warna gelap dan kerutan pelayuan pada tomat “Tua” memiliki output ekuivalen dengan corak penyakit/pembusukan pada tomat “Rusak” [8][9]. Kasus kemiripan anomali visual pembusukan buah yang sulit dipisahkan dari proses pematangan ini juga menjadi tantangan klasifikasi citra multikelas pada buah lainnya [14][15].

Kendala terbesar yang dihadapi oleh kedua model terjadi pada kelas “Rusak”. Baik KNN (benar 232 dari 316 sampel) maupun ANN (benar 152 dari 211 sampel) mengalami titik *False Positives* yang tinggi karena memprediksi tomat “Rusak” sebagai tomat “Tua” (tercatat 52 kesalahan di KNN dan 47 kesalahan di ANN). Dari sudut pandang fitur, fenomena ini dapat dipahami karena tomat yang busuk sering memiliki warna gelap serta tekstur kerutan yang tumpang tindih (*overlap*) secara matematis dengan tomat yang sudah terlampaui matang.



Gambar 5. Confusion Matrix KNN vs ANN

Keunggulan ANN dapat dikaitkan dengan kapabilitas jaringan saraf tiruan dalam mempelajari relasi pola nonlinier yang kompleks dari ruang fitur 10 dimensi. Dengan optimalisasi rasio fitur dan *Dropout* sebesar 20%, ANN tidak terjebak *overfitting* serta berhasil melampaui pendekatan berbasis pengukuran jarak linier (KNN). Walaupun performa uji telah menembus tingkat akurasi adaptasi unggul, koreksi deteksi atas identifikasi misklasifikasi ganda sampel buah busuk dengan citra buah tua masih menjadi titik celah kelemahan spasial yang wajib diatasi. Pengembangan modifikasi algoritma pada fase kelanjutan sangat direkomendasikan untuk mulai bereksperimen dengan penggunaan arsitektur jaringan konvolusi internal agar interpretasi tekstur berdimensi spasial bisa dilatih secara otonom oleh mesin pengolahan tanpa campur tangan kuantifikasi fitur ekstraktif secara manual.

4. Kesimpulan

Rangkaian pengujian metodologi menyimpulkan bahwa integrasi isolasi objek *GrabCut* bersama fusi momen warna ruang HSV dan penyaringan tekstur invarian GLCM empat orientasi secara signifikan mereduksi bias klasifikasi kualitas tomat. Komparasi kinerja arsitektur mengonfirmasi supremasi kerangka kecerdasan *Artificial Neural Network* dalam menavigasi kompleksitas relasi multiclass ketimbang pendekatan jarak linier geometri *K-Nearest Neighbors*. Model ANN sukses merebut puncak evaluasi di tingkat 89.63%, yang diperoleh menggunakan kepadatan lapisan hidden 128 neuron, pembagian data 80:20, serta penahanan propagasi dropout 20%. Meskipun demikian, identifikasi fitur misklasifikasi objek tomat rusak dengan tomat tua masih belum terisolasi sepenuhnya akibat kemiripan profil visual kerusakannya. Rekomendasi perbaikan ke depannya dapat diupayakan

menggunakan kerangka konvolusional otonom agar mesin tidak lagi bergantung eksklusif pada parameter ekstraksi metrik tradisional.

Referensi

1. A. S. Agung, A. F. Dirgantara SR, M. S. Hersyam, A. B. Kaswar, and D. D. Andayani, "Classification of Tomato Quality Based on Color Features and Skin Characteristics Using Image Processing Based Artificial Neural Network," *Jurnal Teknik Informatika (JUTIF)*, vol. 4, no. 5, pp. 1021–1032, Oct. 2023. <https://doi.org/10.52436/1.jutif.2023.4.5.730>
2. N. Arifin, C. N. Insani, and M. R. Rasyid, "Klasifikasi Tingkat Kematangan Buah Tomat Menggunakan Computer Vision untuk Smart Agriculture," *Jurnal SAINTIKOM*, vol. 22, no. 2, pp. 509–516, Aug. 2023. <https://doi.org/10.53513/jis.v22i2.8387>
3. S. W. Agusta and W. Kaswidjanti, "The Implementation of Color Feature Extraction and Gray Level Co-occurrence Matrix Combination in K-Nearest Neighbor Classification Method for Tomato Leaf Disease Identification," *Telematika: Jurnal Informatika dan Teknologi Informasi*, vol. 20, no. 2, pp. 250–262, Jun. 2023. <https://doi.org/10.31315/telematika.v20i2.10009>
4. H. R. Cahyaputra and R. Rahmadewi, "Klasifikasi Tingkat Kematangan Buah Paprika Menggunakan Metode K-Nearest Neighbor Berdasarkan Warna RGB Melalui Aplikasi MATLAB," *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 1, pp. 242–249, Mar. 2024. <https://doi.org/10.29100/jipi.v9i1.4440>
5. A. K. Ulandari, G. K. Ramdhani, Wahyuningsih, M. N. Arwansyuri, and F. Bimantoro, "Klasifikasi Jeruk Segar dan Busuk Melalui GLCM dan HSV dengan Menggunakan Metode ANN," *Prosiding Seminar Nasional Teknologi dan Sains*, vol. 3, pp. 97–102, Jan. 2024. <https://doi.org/10.29407/stains.v3i1.4358>
6. M. Zou, Y. Liu, M. Fu, C. Li, Z. Zhou, H. Meng, E. Xing, and Y. Ren, "Combining spectral and texture feature of UAV image with plant height to improve LAI estimation of winter wheat at jointing stage," *Frontiers in Plant Science*, vol. 14, p. 1272049, Jan. 2024. <https://doi.org/10.3389/fpls.2023.1272049>
7. A. K. Aggarwal, "Learning Texture Features from GLCM for Classification of Brain Tumor MRI Images using Random Forest Classifier," *WSEAS Transactions on Systems*, vol. 21, pp. 83–91, Apr. 2022. <https://doi.org/10.37394/232014.2022.18.8>
8. N. A. Faradita and L. S. Harahap, "Identifikasi Tingkat Kematangan Buah Tomat Melalui Warna dengan Penerapan Jaringan Saraf Tiruan (JST)," *Polygon: Jurnal Ilmu Komputer dan Manajemen Informatika*, vol. 2, no. 6, pp. 20–26, Nov. 2024. <https://doi.org/10.62383/polygon.v2i6.292>
9. I. Amal Ishak, M. Muhammad, and A. B. Kaswar, "Sistem Pendeteksi Kematangan Buah Tomat Berbasis Pengolahan Citra Digital Menggunakan Metode Jaringan Syaraf Tiruan," *Jurnal MediaTIK*, vol. 5, no. 1, pp. 65–69, Jan. 2022. <https://doi.org/10.59562/mediatik.v5i1.1384>
10. G. J. Massie, A. Z. Pratama, T. P. Sakira, A. B. Kaswar, And D. D. Andayani, "Maturity Classification System Of Tomato Based On Rgb Color Features Using Backpropagation Artificial Neural Network Method", *J. Tek. Inform. (Jutif)*, Vol. 5, No. 1, Pp. 1–10, Jan. 2024. <https://doi.org/10.52436/1.jutif.2024.5.1.732>
11. A. B. M. . Widat, A. . Baijuri, and F. . Lazim, "Classification of Tomato Fruit Image Ripeness Based on Color Feature Extraction Using the K-NN Method", *G-Tech*, vol. 8, no. 3, pp. 1779–1786, Jul. 2024. <https://doi.org/10.33379/gtech.v8i3.4539>
12. M. Faqihuddin and R. A. Purnama, "Komparasi SVM dan Random Forest Berbasis Histogram Warna untuk Deteksi Penyakit Anggur", *JTEKSIS*, vol. 8, no. 1, pp. 34–39, Jan. 2026. <https://doi.org/10.47233/jteksis.v8i1.2340>
13. C. Imam, E. W. Hidayat, and N. I. Kurniati, "Classification of Meat Imagery Using Artificial Neural Network Method and Texture Feature Extraction By Gray Level Co-Occurrence Matrix Method," *Jurnal Teknik Informatika (Jutif)*, vol. 2, no. 1, pp. 1–8, 2021. <https://doi.org/10.20884/1.jutif.2021.2.1.37>
14. S. M. Syadham and M. Akbar, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Gray Level Co-Occurrence Matrix-Convolutional Neural Network," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 13, no. 3, pp. 1367–1376. <https://doi.org/10.23960/jitet.v13i3.7274>
15. I. Ismail, N. Arifin, and Prihastinur, "Klasifikasi Kematangan Buah Naga Berdasarkan Fitur Warna menggunakan Algoritma Multi-Class Support Vector Machine," *J. Inform. Teknol. Dan Sains*, vol. 5, no. 1, pp. 121–126, Feb. 2023. <https://doi.org/10.51401/jinteks.v5i1.2203>