

DETEKSI JERUK NIPIS DAN JERUK JUNGGA MENGGUNAKAN ALGORITMA CNN

**Alvin Hafiz, Asri Angel Tumanggor, Martince Delvin Ibo,
Muhammad Yazid Noor, Kalpin Palendeo Sitepu, Hermawan Syahputra**

Ilmu Komputer, Universitas Negeri Medan
Jl. William Iskandar Ps. V, Kenangan Baru, Kec. Percut Sei Tuan
Kabupaten Deli Serdang, Sumatera Utara, Indonesia
alvinhafiz1145@gmail.com

ABSTRAK

Jeruk nipis (*Citrus aurantifolia*) dan jeruk jungga (*Citrus jambhiri* Lush) merupakan dua jenis buah yang memiliki nilai ekonomi tinggi di Indonesia, namun sulit dibedakan secara visual dalam kondisi mentah. Masalah ini menyebabkan ketidaktepatan dalam proses sortir manual yang dilakukan petani atau distributor, berpotensi menimbulkan kerugian ekonomi. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis menggunakan metode pengolahan citra digital dan algoritma Convolutional Neural Network (CNN) guna membedakan jeruk nipis dan jeruk jungga secara efisien dan akurat. Dataset terdiri dari 100 citra dengan karakteristik warna dan tekstur yang berbeda. Metode yang digunakan meliputi pra-pemrosesan (resizing, normalisasi, denoising, konversi ke grayscale), segmentasi (thresholding dan edge detection), ekstraksi fitur (RGB untuk warna dan GLCM untuk tekstur), serta pelatihan model CNN. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi pelatihan sebesar 90% dan validasi 85%. Analisis nilai RGB menunjukkan perbedaan signifikan pada komponen G dan B, sedangkan GLCM mengindikasikan bahwa jeruk jungga memiliki tekstur lebih kasar daripada jeruk nipis. Namun, confusion matrix menunjukkan bahwa model masih mengalami kesalahan klasifikasi terhadap jeruk nipis, menghasilkan akurasi keseluruhan sebesar 52,9%. Oleh karena itu, diperlukan peningkatan kualitas model dan strategi augmentasi data untuk hasil klasifikasi yang lebih optimal.

Kata kunci : *Klasifikasi Citra, CNN, GLCM, Ekstraksi Fitur, Jeruk Jungga, Jeruk Nipis*

1. PENDAHULUAN

Buah-buahan merupakan salah satu kelompok produk pertanian di Indonesia yang memiliki permintaan cukup besar. Sebagai contoh, buah jeruk, apel, dan pisang merupakan jenis buah yang banyak ditemukan di Indonesia dan disukai oleh masyarakat luas [1].

Jeruk merupakan salah satu jenis buah yang tumbuh optimal di daerah bersuhu subtropis dengan kisaran suhu antara 20-30 derajat celcius. Selain faktor suhu, pertumbuhan jeruk juga bergantung pada intensitas sinar matahari yang diterimanya [2]. Jeruk nipis (*Citrus aurantifolia*) dan jeruk jungga (*Citrus jambhiri* Lush) merupakan dua jenis jeruk yang memiliki nilai ekonomi tinggi di Indonesia. Keduanya banyak digunakan dalam berbagai industri, seperti makanan, minuman, kosmetik, dan kesehatan. Jeruk nipis dikenal dengan kandungan vitamin C-nya yang tinggi dan sering digunakan sebagai bahan penyedap masakan atau obat tradisional, sedangkan jeruk jungga lebih populer sebagai buah untuk dikonsumsi langsung karena rasanya yang manis dan segar.

Terlepas dari perbedaan rasa dan kegunaannya yang signifikan, jeruk nipis dan jeruk jungga sering kali sulit untuk dibedakan secara visual, terutama ketika masih dalam bentuk buah utuh atau mentah. Proses identifikasi manual yang dilakukan oleh petani atau distributor sering kali memakan waktu, tidak akurat, dan rentan terhadap kesalahan manusia. Hal ini dapat menyebabkan ketidakakuratan dalam proses penyortiran, yang berpotensi menyebabkan kerugian ekonomi.

Solusi untuk masalah ini disediakan oleh pemrosesan gambar digital di era teknologi yang canggih ini. Algoritma Convolutional Neural Network (CNN), yang merupakan komponen dari deep learning, adalah salah satu metode yang efisien. CNN sesuai untuk pekerjaan klasifikasi gambar karena dapat secara otomatis mempelajari aspek-aspek penting dari sebuah gambar. Selain itu, akurasi klasifikasi dapat ditingkatkan dengan menggunakan RGB (Red, Green, Blue) untuk analisis warna dan Gray Level Co-occurrence Matrix (GLCM) untuk analisis tekstur.

Tujuan dari penelitian ini adalah untuk menciptakan sistem klasifikasi otomatis yang dapat membedakan jeruk jungga dan jeruk nipis secara andal dan cepat. Diharapkan bahwa metode ini akan meningkatkan efisiensi dan mengurangi kerugian finansial dengan membantu petani, pedagang grosir, dan sektor terkait dalam proses identifikasi. Selain itu, penelitian ini juga diharapkan dapat memajukan teknologi pengolahan citra digital, khususnya di bidang hortikultura dan pertanian.

2. TINJAUAN PUSTAKA**2.1. Penelitian Terdahulu**

Dalam penelitian sebelumnya yang dilakukan oleh Samuel Siagian, Khairi Ibnutama, dan Rina Mahyuni, yakni penggunaan teknik ekstraksi fitur warna pada foto digital untuk menentukan tingkat kematangan buah jeruk secara otomatis. Untuk menentukan tingkat kematangan buah jeruk, penelitian ini menggunakan pendekatan ekstraksi fitur warna dalam ruang warna RGB. Teknik ini digunakan dalam

program pengolah gambar desktop yang dapat menentukan kematangan jeruk secara otomatis [3].

Selain itu, menurut sebuah penelitian oleh Yazid Fauzan Nur Ashfani, Yovi Litanianda, dan Rizqy Amalia Putri, algoritma CNN sangat tepat untuk mengidentifikasi berbagai jenis buah secara otomatis karena dapat secara efektif mengenali pola visual yang rumit [4].

2.2. Pengolahan Citra Digital

Studi ilmiah tentang metode pemrosesan gambar yang berbeda dikenal sebagai pemrosesan citra digital. Citra yang dimaksud dapat berupa gambar bergerak (dari webcam, misalnya) atau gambar diam (foto) [5]. Citra merupakan salah satu jenis informasi visual yang dapat dipelajari lebih lanjut karena mengandung berbagai macam data. Pengolahan citra digital adalah proses mengeluarkan informasi dari foto untuk menciptakan output yang berguna untuk berbagai macam penggunaan [6]. Perubahan diperlukan untuk meningkatkan kualitas gambar yang terganggu sehingga dapat lebih mudah dipahami oleh manusia dan robot. Tujuan dari pemrosesan gambar, khususnya dengan bantuan komputer, adalah untuk memperbaiki dan meningkatkan kualitas gambar agar lebih jelas dan instruktif [7].

Komputasi matematis pada tingkat piksel dan berdasarkan pada struktur geometris objek dapat digunakan dalam teknik pemrosesan gambar. Karena setiap objek dalam gambar memiliki kualitas yang berbeda yang dapat diukur secara kuantitatif, maka dimungkinkan untuk mengidentifikasi perbedaan di antara mereka [8].

2.3. Convolutional Neural Network (CNN)

Multilayer Perceptron (MLP) dikembangkan menjadi Convolutional Neural Networks (CNN), yang secara khusus dibuat untuk menangani input dua dimensi, seperti foto. Karena CNN memiliki struktur jaringan yang dalam dengan beberapa lapisan, CNN termasuk dalam kategori jaringan saraf dalam dan sering digunakan dalam pemrosesan gambar [9].

Input, ekstraksi fitur, klasifikasi, dan output adalah tahapan umum yang membentuk struktur CNN. CNN menggunakan sejumlah lapisan dalam proses ekstraksi fitur, termasuk lapisan penyatuan, fungsi aktivasi (seperti ReLU), dan lapisan konvolusi. CNN berfungsi secara berurutan, menciptakan proses yang terorganisir dengan menggunakan output dari satu lapisan sebagai input untuk lapisan berikutnya [10]. Karena dapat mengekstrak informasi dari gambar, pendekatan Convolutional Neural Network (CNN) sangat populer di bidang deep learning. CNN memiliki kemampuan untuk mengurangi ukuran gambar tanpa mengorbankan fitur utamanya [11].

2.4. Gray Level Co-occurrence Matrix (GLCM)

Salah satu teknik untuk mengekstraksi fitur dari suatu gambar adalah Gray Level Co-occurrence Matrix (GLCM). Untuk menemukan pola tekstur,

teknik ini memeriksa bagaimana tingkat abu-abu suatu gambar berhubungan satu sama lain [12].

Matriks ketergantungan spasial tingkat keabuan adalah nama lain dari Gray Level Co-occurrence Matrix, atau GLCM. Teknik ini menentukan frekuensi kemunculan pasangan piksel dengan nilai tertentu dalam hubungan spasial yang telah ditentukan sebelumnya untuk memeriksa tekstur gambar. Sifat tekstur gambar dapat dijelaskan dengan mengekstraksi beberapa ukuran statistik dari matriks GLCM setelah dibuat [13]. Piksel dengan intensitas i dibandingkan dengan piksel tetangganya dengan intensitas j pada jarak d dan pada arah tertentu sesuai dengan sudut θ . Inilah cara GLCM menghitung pasangan piksel yang berbeda berdasarkan intensitasnya. Empat orientasi sudut utama yang digunakan oleh GLCM pada umumnya adalah 0° , 45° , 90° , dan 135° [14].

2.5. Model Warna RGB

Merah, hijau, dan biru adalah tiga warna primer yang dapat dikombinasikan untuk menciptakan berbagai rona warna yang berbeda dalam skema warna RGB, yang bersifat aditif. Menurut hipotesis ini, memadukan cahaya dari ketiga rona akan memperluas spektrum warna dengan menambah panjang gelombang masing-masing [15]. Kombinasi nilai merah, hijau, dan biru yang disimpan dalam setiap saluran warna pada lokasi piksel tertentu menentukan warna setiap piksel dalam manajemen warna RGB, yang menggunakan skala intensitas dari 0 hingga 255. Merah, hijau, dan biru adalah tiga komponen warna gambar RGB, yang biasanya dikodekan dalam format 24-bit dengan kedalaman 8-bit [16].

Model warna RGB dapat digunakan dalam berbagai aplikasi pemrosesan gambar, termasuk sistem yang mengenali uang kertas untuk tuna netra dan tuna netra. Namun demikian, untuk meningkatkan akurasi analisis warna, teknik RGB biasanya digunakan bersama dengan model HSV [17].

2.6. Segmentasi Citra

Proses pemisahan gambar digital menjadi piksel individu atau kelompok piksel, yang dikenal sebagai superpiksel, disebut segmentasi. Tujuan utama segmentasi adalah untuk mengubah atau menyederhanakan representasi visual agar lebih mudah dipahami dan dievaluasi [18]. Dua sifat utama dari nilai intensitas-keseragaman dan kontinuitas-biasanya menjadi dasar dari algoritme segmentasi gambar. Segmentasi berbasis kontinuitas, juga disebut sebagai deteksi tepi, membagi gambar menurut perubahan intensitas secara keseluruhan. Sebaliknya, segmentasi berbasis keseragaman membagi gambar menurut tingkat homogenitas di suatu wilayah [19].

Segmentasi memungkinkan untuk mengidentifikasi setiap objek individu dalam gambar dan memanfaatkan informasi tersebut sebagai masukan untuk pemrosesan tambahan. Segmen adalah kumpulan piksel yang muncul selama segmentasi [20].

2.7. Penerapan Teknologi Deep Learning dalam Pertanian

Di bidang pertanian, teknologi deep learning telah digunakan secara luas untuk berbagai tugas, termasuk prediksi produksi pertanian, deteksi penyakit tanaman, dan klasifikasi tanaman.

Proses ini melibatkan pelatihan dan pengujian menggunakan sejumlah besar kumpulan data berlabel. Data tersebut kemudian diubah menjadi nilai piksel pada gambar, yang selanjutnya digunakan sebagai representasi internal atau vektor fitur untuk analisis lebih lanjut [21]. Deep learning menjadi populer karena karakteristiknya yang meliputi kemampuan untuk mempelajari fitur yang lebih abstrak, mengurangi kompleksitas pelatihan model, akurasi yang tinggi, kemampuan untuk menangani data dalam jumlah besar, dan dukungan untuk transfer learning [22].

3. METODE PENELITIAN

3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah gambar jeruk nipis dan jeruk jungga. Proses pengumpulan data dilakukan dengan cara:

- Mengambil foto jeruk nipis dan jeruk jungga dari berbagai sudut dan kondisi pencahayaan.
- Mengumpulkan dataset gambar dari sumber online yang terpercaya.
- Melakukan preprocessing data, seperti resizing gambar dan normalisasi warna.

3.2. Akurasi Data

Sebelum memulai proses analisis, penting untuk memastikan bahwa data yang digunakan akurat dan representatif. Langkah-langkahnya meliputi:

- Validasi Data: Memeriksa apakah gambar yang dikumpulkan benar-benar merupakan jeruk nipis dan jeruk jungga.
- Pembersihan Data: Menghapus gambar yang tidak jelas, rusak, atau tidak relevan.
- Pembagian Data: Membagi dataset menjadi data latih (training data), data validasi (validation data), dan data uji (testing data) dengan rasio 70:20:10.

3.3. Pra-Pemrosesan

Pra-pemrosesan dilakukan untuk menyiapkan data agar siap digunakan dalam proses analisis. Tahapannya meliputi:

- Resizing: Mengubah ukuran gambar menjadi dimensi yang seragam (misalnya, 224x224 piksel) untuk konsistensi.
- Normalisasi: Mengubah nilai intensitas piksel ke rentang 0 hingga 1 dengan rumus:

$$I_{\text{norm}}(x, y) = \frac{I(x, y) - I_{\text{min}}}{I_{\text{max}} - I_{\text{min}}} \quad (1)$$

Di mana:

- $I_{\text{norm}}(x, y)$ adalah nilai piksel setelah normalisasi.
- $I(x, y)$ adalah nilai piksel asli.
- I_{min} adalah nilai piksel minimum dalam gambar.
- I_{max} adalah nilai piksel maksimum dalam gambar.

- Augmentasi Data: Meningkatkan variasi data dengan teknik seperti rotasi, flipping, dan perubahan brightness untuk mencegah overfitting.

3.4. Segmentasi

Segmentasi bertujuan untuk memisahkan objek (jeruk) dari latar belakang. Metode yang digunakan adalah:

- Thresholding: Menggunakan nilai ambang (threshold) untuk memisahkan objek berdasarkan intensitas piksel.

$$I_{\text{seg}}(x, y) = \begin{cases} 1 & \text{jika } I(x, y) \geq T \\ 0 & \text{jika } I(x, y) < T \end{cases} \quad (2)$$

Di mana T adalah nilai threshold.

- Edge Detection: Menggunakan operator seperti Canny atau Sobel untuk mendeteksi tepi objek.

3.5. Ekstraksi Fitur

Ekstraksi fitur bertujuan untuk mengidentifikasi karakteristik penting dari citra jeruk nipis dan jeruk jungga. Dua metode utama yang digunakan adalah GLCM (Gray Level Co-occurrence Matrix) untuk analisis tekstur dan RGB (Red, Green, Blue) untuk analisis warna.

- GLCM adalah metode statistik yang digunakan untuk menganalisis tekstur citra dengan menghitung hubungan spasial antara piksel. Prosesnya melibatkan pembuatan matriks yang merepresentasikan frekuensi kemunculan pasangan piksel dengan intensitas tertentu. Rumus dasar untuk menghitung GLCM adalah:

$$P(i, j) = \frac{C(i, j)}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} C(i, j)} \quad (3)$$

Di mana:

- $P(i, j)$: $P(i, j)$ adalah probabilitas kemunculan pasangan piksel dengan intensitas i dan j
 - $C(i, j)$: $C(i, j)$ adalah jumlah kemunculan pasangan piksel dengan intensitas i dan j
 - N : N adalah jumlah level intensitas (biasanya 256 untuk citra 8-bit).
- RGB adalah model warna yang merepresentasikan warna berdasarkan kombinasi intensitas merah, hijau, dan biru. Setiap piksel dalam citra memiliki tiga nilai intensitas (R, G, B) yang dapat digunakan untuk membedakan warna kulit jeruk nipis dan jeruk jungga.

3.6. Pembuatan Model CNN

CNN (Convolutional Neural Network) adalah algoritma deep learning yang dirancang khusus untuk memproses data citra. Arsitektur CNN terdiri dari beberapa lapisan, yaitu:

- Convolutional Layer: Melakukan ekstraksi fitur menggunakan operasi konvolusi. Rumus operasi konvolusi adalah:

$$(f * g)(x, y) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} f(i, j) \cdot g(x - i, y - j) \quad (4)$$

Di mana:

- f : f adalah citra input.
- g : g adalah kernel/filter.
- (x, y) : (x, y) adalah posisi piksel.

4. HASIL DAN PEMBAHASAN

4.1. Analisis Data Awal

Pada tahap analisis data awal, dataset yang digunakan terdiri dari citra jeruk nipis dan jeruk jungga. Dataset ini dikumpulkan dari pengambilan gambar objek penelitian. Jumlah total citra yang digunakan adalah 100 dataset.

Dataset terdiri dari citra jeruk jungga dan jeruk nipis dengan karakteristik berbeda, di mana jeruk jungga berwarna hijau tua, bertekstur kasar, dan berukuran besar, sedangkan jeruk nipis berwarna hijau muda hingga kuning, bertekstur halus, dan berukuran lebih kecil. Seluruh citra memiliki resolusi 3060 x 4080, namun beberapa mengandung noise seperti bayangan dan refleksi cahaya. Distribusi dataset seimbang, tetapi tantangan muncul akibat kemiripan warna antara jeruk yang belum matang serta tekstur kulit jeruk jungga yang dapat menyulitkan ekstraksi fitur. Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian, dengan ukuran rata-rata jeruk jungga 5-10 cm dan jeruk nipis 3-8 cm.



Gambar 1. Jeruk jungga



Gambar 2. Jeruk nipis


4.2. Hasil Pra-Pemrosesan

Pra-pemrosesan citra dilakukan untuk meningkatkan kualitas data sebelum tahap segmentasi, ekstraksi fitur, dan klasifikasi. Langkah pertama adalah resizing citra menjadi 128 piksel menggunakan interpolasi bilinear untuk menyeragamkan ukuran. Selanjutnya, normalisasi intensitas cahaya dengan histogram equalization diterapkan untuk mengurangi variasi pencahayaan dan meningkatkan kontras. Penghapusan noise menggunakan Gaussian dan median filter berhasil mengurangi gangguan seperti bayangan dan refleksi cahaya. Kontras citra ditingkatkan dengan contrast stretching untuk memperjelas perbedaan antara objek dan latar belakang. Citra kemudian dikonversi ke grayscale guna menyederhanakan analisis fitur tekstur dan bentuk. Terakhir, segmentasi awal dengan thresholding berhasil memisahkan objek dari latar belakang, meskipun masih memerlukan penyempurnaan pada beberapa area.

Visualisasi hasil pra-pemrosesan mencakup beberapa tahap penting. Citra asli menampilkan jeruk jungga dan jeruk nipis sebelum diproses. Setelah resizing, citra memiliki ukuran seragam. Normalisasi dan denoising menghasilkan pencahayaan yang lebih seimbang serta mengurangi noise. Terakhir, citra grayscale disiapkan untuk proses segmentasi guna memfokuskan analisis pada fitur tekstur dan bentuk.



Gambar 3. Citra sebelum pra-pemrosesan



Gambar 4. Citra setelah pra-pemrosesan

4.3. Hasil Pengujian


Hasil penelitian mencakup analisis nilai rata-rata RGB, ekstraksi fitur tekstur dengan GLCM, dan klasifikasi menggunakan CNN untuk mengevaluasi kemampuan sistem dalam membedakan jeruk jungga dan jeruk nipis berdasarkan warna, tekstur, dan model deep learning.

```

Kelas: jeruk_nipis
Rata-rata R: 157.79
Rata-rata G: 162.21
Rata-rata B: 154.65
-----
Kelas: jeruk_jungga
Rata-rata R: 148.08
Rata-rata G: 154.12
Rata-rata B: 142.26

```


Gambar 4. Rata-rata nilai RGB untuk dua kelas citra



Gambar 5. Diagram batang rata-rata nilai RGB untuk kedua kelas citra


Pada hasil analisis rata-rata nilai RGB menunjukkan perbedaan warna antara jeruk jungga dan jeruk nipis. Jeruk jungga memiliki warna dominan hijau tua dengan nilai R = 148.08, G = 154.12, dan B = 142.26, sedangkan jeruk nipis cenderung berwarna hijau muda dengan nilai R = 157.79, G = 162.21, dan B = 154.65, yang berubah menjadi kuning saat matang. Perbedaan signifikan pada nilai Green (G) dan Blue (B) dapat digunakan sebagai fitur utama dalam klasifikasi.

Pada ekstraksi fitur tekstur menggunakan GLCM, dilakukan untuk membedakan jeruk jungga dan jeruk nipis berdasarkan karakteristik teksturnya. Hasil analisis menunjukkan bahwa jeruk jungga memiliki contrast lebih tinggi (3.4) karena teksturnya yang kasar dan bergelombang, sementara jeruk nipis memiliki energy (0.2) dan homogeneity (0.7) lebih tinggi, menunjukkan tekstur yang lebih halus. Perbedaan ini dapat digunakan sebagai fitur pembeda dalam klasifikasi citra.



Gambar 6. Diagram batang perbandingan fitur tekstur GLCM pada kedua kelas citra


Pada model CNN, digunakan untuk mengklasifikasikan citra jeruk jungga dan jeruk nipis berdasarkan fitur yang dipelajari.



Gambar 7. Grafik akurasi dan loss model CNN selama proses pelatihan

Akurasi training meningkat hingga 90%, sedangkan akurasi validation mencapai 85%, menunjukkan model mampu mengenali pola tanpa overfitting. Penurunan loss training dan validation hingga masing-masing 0.2 dan 0.3 menegaskan bahwa model semakin akurat dalam memprediksi. Tren akurasi dan loss yang stabil menunjukkan bahwa CNN berhasil belajar fitur penting dari citra dan mencapai konvergensi dengan baik.

Pada confusion matrix, digunakan untuk mengevaluasi performa model klasifikasi dengan membandingkan prediksi terhadap label sebenarnya. Model berhasil mengklasifikasikan semua Jeruk Jungga dengan benar (TP = 18), tetapi gagal mengenali Jeruk Nipis, karena semua citranya diprediksi sebagai Jeruk Jungga (FP = 16, TN = 0, FN = 0). Akurasi model sebesar 52.9%, dengan presisi 52.9%, recall 100%, dan F1-score 69.2%. Kelebihan model adalah recall yang tinggi untuk Jeruk Jungga, tetapi kelemahannya adalah kesulitan dalam membedakan Jeruk Nipis, yang menyebabkan akurasi dan presisi rendah.



Gambar 8. Confusion matrix dalam membedakan jeruk jungga dan jeruk nipis

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa teknik pengolahan citra digital dapat digunakan untuk membedakan jeruk jungga dan jeruk nipis berdasarkan warna, tekstur, dan fitur model klasifikasi berbasis

CNN. Hasil pra-pemrosesan, seperti normalisasi luminance dan pemfilteran, berhasil meningkatkan kualitas citra dengan mengurangi noise dan meningkatkan kontras. Analisis fitur warna menunjukkan perbedaan yang signifikan pada nilai RGB, sedangkan ekstraksi fitur tekstur dengan GLCM membuktikan bahwa tekstur jeruk jingga lebih kasar daripada jeruk nipis. Model CNN mencapai akurasi pelatihan 90% dan validasi 85%, tetapi kinerja klasifikasi menunjukkan kelemahan dalam mengenali jeruk nipis, dengan akurasi keseluruhan 52,9%. Untuk meningkatkan kinerja model, disarankan untuk menyeimbangkan jumlah data pelatihan antar kelas, mengeksplorasi arsitektur CNN yang lebih kompleks, dan menerapkan teknik augmentasi data untuk meningkatkan generalisasi model ke berbagai macam gambar.

DAFTAR PUSTAKA

- [1] S. Napitu, R. Paramita Panjaitan, P. A. Nulhakim, and M. Khalik Lubis, "Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan HSV Menggunakan Metode KNN," *J. SAINTEKOM*, vol. 13, no. 2, pp. 214–221, 2023, doi: 10.33020/saintekom.v13i2.420.
- [2] 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 Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 9, no. 2, pp. 756–767, 2024, doi: 10.29100/jupi.v9i2.5384.
- [3] S. Siagian, K. Ibnutama, and R. Mahyuni, "Implementasi Metode Ekstraksi Ciri Warna Untuk Mendeteksi Kematangan Buah Jeruk," vol. 1, no. November, pp. 898–905, 2022.
- [4] Yazid Fauzan Nur Ashfani, Yovi Litanianda, and Rizqy Amalia Putri, "Klasifikasi Jenis Buah Jeruk Menggunakan Metode Convolutional Neural Network: Deep Learning Studi," *Uranus J. Ilm. Tek. Elektro, Sains dan Inform.*, vol. 2, no. 2, pp. 70–79, 2024, doi: 10.61132/uranus.v2i2.129.
- [5] Tri Laksono Aditiya, Endryansyah, Wanarti Rusmamto Puput, and Syariffuddin Zuhrie Muhammad, "Pengolahan Citra Digital Buah Murbei Dengan Algoritma LDA (Linear Discriminant Analysis)," *Indones. J. Eng. Technol.*, vol. 4, no. 2, pp. 71–78, 2022, [Online]. Available: <https://journal.unesa.ac.id/index.php/inajet>
- [6] P. Bangun and M. Sihombing, "Pengolahan Citra Untuk Identifikasi Kematangan Buah Jeruk Dengan Menggunakan Metode Backpropagation Berdasarkan Nilai Hsv," *J. Tek. Inform. Kaputama*, vol. 5, no. 1, pp. 85–91, 2021.
- [7] M. T. Informatika, U. Putra, and I. Yptk, "Klasifikasi Citra Dalam Identifikasi Jeruk Nipis dan Jeruk Mandarin Menggunakan Convolutional Neural Network (CNN) Dan Optimalisasi Median Filter," vol. 6, no. 1, pp. 56–64, 2025.
- [8] A. Mulyanto, E. Susanti, F. Rossi, W. Wajiran, and R. I. Borman, "Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR)," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 1, p. 52, 2021, doi: 10.26418/jp.v7i1.44133.
- [9] Adela Regita Azzahra, Purnawansyah, H. Darwis, and D. Widyawati, "Klasifikasi Daun Herbal Menggunakan Metode CNN dan Naïve Bayes dengan Fitur GLCM," *Indones. J. Comput. Sci.*, vol. 12, no. 4, 2023, doi: 10.33022/ijcs.v12i4.3362.
- [10] M. Dandi Darajat, Y. A. Sari, and R. C. Wihandika, "Convolutional Neural Network untuk Klasifikasi Citra Makanan Khas Indonesia," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 11, pp. 4764–4769, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [11] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [12] F. Haikal, M. Razak, and N. Umar, "Citra Digital Untuk Klasifikasi Kualitas Udang Windu Menggunakan Algoritma GLCM dan K-Nearest Neighbor," *J. Inform.*, vol. 9, no. 2, pp. 93–102, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/ji>
- [13] N. Neneng, A. S. Puspaningrum, and A. A. Aldino, "Perbandingan Hasil Klasifikasi Jenis Daging Menggunakan Ekstraksi Ciri Tekstur Gray Level Co-occurrence Matrices (GLCM) Dan Local Binary Pattern (LBP)," *Smatika J.*, vol. 11, no. 01, pp. 48–52, 2021, doi: 10.32664/smatika.v11i01.572.
- [14] F. Agustina and Z. A. Ardiansyah, "Identifikasi Citra Daging Ayam Kampung dan Broiler Menggunakan Metode GLCM dan Klasifikasi-NN Image Identification of Local Chicken Meat and Broiler Chicken Meat Using GLCM Method and K-NN Classification," 25 *J. Infokam*, vol. XVI, no. 1, 2020.
- [15] H. A. Rabbani, M. A. Rahman, and B. Rahayudi, "Perbandingan Ruang Warna RGB dan HSV dalam Klasifikasi Kematangan Biji Kopi," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 6, pp. 2243–2248, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [16] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [17] K. B. D. R. Nur Widyasari, U. D. Rosiani, and A. N. Pramudhita, "Implementasi Sistem Pendeteksi

- Tingkat Kematangan Buah Pepaya Menggunakan Metode RGB,” *Smatika J.*, vol. 11, no. 01, pp. 32–36, 2021, doi: 10.32664/smatika.v11i01.536.
- [18] F. A. P. Efran, Khairil, and J. Jumadi, “Implementasi Metode K-Means Clustering Pada Segmentasi Citra Digital,” *J. Media Infotama*, vol. 18, no. 2, pp. 291–301, 2022.
- [19] K. A. Lubis, M. Rusdi, and S. Sugianto, “Proses Segmentasi Citra Satelit Untuk Pemetaan Tutupan Lahan (Satellite Image Segmentation Process for Land Cover Mapping),” *JFP J. Ilm. Mhs. Pertan.*, vol. 6, no. 4, pp. 691–698, 2021, [Online]. Available: www.jim.unsyiah.ac.id/JFP
- [20] R. S. D. Wijaya, Adiwijaya, Andriyan B Suksmono, and Tati LR Mengko, “Segmentasi Citra Kanker Serviks Menggunakan Markov Random Field dan Algoritma K-Means,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 139–147, 2021, doi: 10.29207/resti.v5i1.2816.
- [21] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, “Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 1, pp. 59–66, 2023, doi: 10.25126/jtiik.20231015695.
- [22] Zen Munawar and Novianti Indah Putri, “Keamanan IoT Dengan Deep Learning dan Teknologi Big Data,” *Tematik*, vol. 7, no. 2, pp. 161–185, 2020, doi: 10.38204/tematik.v7i2.479.