

Klasifikasi Tingkat Kualitas Terung dengan Algoritma *Backpropagation* Berbasis Fitur Warna dan Tekstur

<http://dx.doi.org/10.28932/jutisi.v11i2.10655>

Riwayat Artikel

Received: 20 Desember 2024 | Final Revision: 25 Juli 2025 | Accepted: 01 Agustus 2025

Creative Commons License 4.0 (CC BY – NC) 

Muh Raflyawan R^{#1}, Reza Arifky^{#2}, Andi Afrah Tenrijeng^{#3}, Andi Baso Kaswar^{✉#4}, Dyah Darma Andayani^{#5}, Putri Alysia Azis^{#6}

[#] Program studi Teknik Komputer, Universitas Negeri Makassar

Jl. A. P. Pettarani, Tidung, Kec. Rappocini, Kota Makassar, Sulawesi Selatan 90222, Indonesia

¹raflyawan04@gmail.com

²rezaarifky@gmail.com

³afrahtenri@gmail.com

⁴a.baso.kaswar@unm.ac.id

⁵dyahdharma@unm.ac.id

⁶putrialysia.djarre@gmail.com

✉ Corresponding author: a.baso.kaswar@unm.ac.id

Abstrak — Penilaian kualitas terung secara manual sering kali tidak konsisten, membutuhkan waktu yang lama, serta rentan terhadap kesalahan akibat kelelahan pekerja. Penelitian ini bertujuan mengembangkan sistem otomatis berbasis pengolahan citra digital untuk menilai kualitas terung secara efisien dan akurat. Tahapannya dimulai dengan pengambilan citra menggunakan perangkat handphone yang dirancang untuk memastikan pencahayaan stabil dan latar belakang seragam. Citra yang diperoleh kemudian diproses melalui segmentasi menggunakan metode *thresholding Otsu* serta operasi morfologi untuk memisahkan objek utama dari latar belakang. Fitur warna dan tekstur diekstraksi melalui analisis *Gray-Level Co-occurrence Matrix* (GLCM) dan ruang warna RGB, HSV, serta LAB. Data pelatihan sebesar 90% dari total dataset digunakan untuk melatih model klasifikasi berbasis jaringan saraf tiruan dengan algoritma *backpropagation*, sementara 10% sisanya digunakan untuk pengujian. Hasil eksperimen menunjukkan bahwa kombinasi fitur LAB, RGB, HSV, dan tekstur memberikan hasil terbaik, dengan akurasi pengujian sebesar 86%, *recall* 85%, dan *precision* 92%. Model ini sangat efektif mendeteksi terung berkualitas buruk dengan akurasi 100%. Sistem ini dapat mendukung penerapan teknologi di sektor hortikultura.

Kata kunci — *Backpropagation*; Fitur Warna dan Tekstur; Jaringan Saraf Tiruan; Kualitas Terung; Pengolahan Citra Digital.

Eggplant Quality Classification Using Backpropagation Algorithm Based on Color and Texture Features

Abstract — *Manual quality assessment of eggplant is often inconsistent, takes a long time, and is prone to errors due to worker fatigue. This research aims to develop an automated system based on digital image processing to assess eggplant quality efficiently and accurately. The stages begin with image capture using a mobile phone device designed to ensure stable lighting and uniform background. The acquired image is then processed through segmentation using the Otsu thresholding method as well as morphological operations to separate the main object from the background. Color and texture features are extracted through Gray-Level Co-occurrence Matrix (GLCM) analysis and RGB, HSV, and LAB color spaces. Training data amounting to 90% of the total dataset was used to train an artificial neural network-based classification model with a backpropagation algorithm, while the remaining 10% was used for testing. Experimental results showed that the combination of LAB, RGB, HSV, and texture features gave the best results, with a testing accuracy of 86%, recall of 85%, and precision of 92%. This model is very effective in detecting poor quality eggplants with 100% accuracy. This system can support the application of technology in the horticultural sector.*

Keywords — Artificial Neural Network; Backpropagation; Color and Texture Features; Digital Image Processing; Eggplant Quality.

I. PENDAHULUAN

Sektor pertanian, terutama dalam bidang hortikultura, memiliki peran yang sangat signifikan bagi perekonomian baik secara global maupun nasional. Salah satu tanaman yang banyak dikenal dan dikonsumsi oleh masyarakat adalah Terung, yang dalam istilah sehari-hari disebut juga Terong. Tanaman ini memiliki nama ilmiah *Solanum melongena*, sebagaimana diuraikan dalam Kamus Besar Bahasa Indonesia (KBBI). Tumbuhan ini termasuk salah satu produk hortikultura yang sering dikonsumsi oleh masyarakat. Salah satu jenis terung yang paling populer adalah terung ungu, sayuran yang kaya nutrisi dan banyak digunakan dalam berbagai hidangan [1].

Menurut data dari Badan Pusat Statistik, produksi terung di Indonesia pada tahun 2023 tercatat dalam kategori sayuran musiman. Jumlah total produksi terung sepanjang tahun mencapai 6.998.963 kuintal, dengan produksi terbesar pada bulan Juni mencapai 653.726 kuintal dan paling sedikit pada bulan Desember, yaitu 476.627 kuintal. Total luas panen sayuran tersebut adalah 49.458 m² [2]. Berdasarkan data dalam buku Statistik Konsumsi Pangan 2023, rata-rata konsumsi terung per kapita di Indonesia pada tahun 2023 mencapai 2,975 kg per tahun, sedikit meningkat dibandingkan tahun 2022 yang sebesar 2,885 kg per kapita. Namun, penyediaan terung mengalami penurunan tajam sebesar 23,32%, dari 692 ribu ton pada 2022 menjadi 530 ribu ton pada 2023. Akibatnya, ketersediaan terung per kapita juga menurun secara signifikan sebesar 24,98%, dari 2,48 kg pada tahun 2022 menjadi 1,86 kg pada tahun 2023 [3].

Selain jumlah dan ketersediaannya, kualitas terung yang diterima oleh konsumen memainkan peran penting dalam menentukan nilai jual dan kepuasan pelanggan. Kualitas yang rendah dapat dipengaruhi oleh berbagai faktor, seperti cacat fisik, kerusakan akibat serangan serangga, serta ketidaksesuaian ukuran atau bentuk dengan standar pasar. Faktor-faktor ini secara langsung dapat memengaruhi harga jual terung [4]. Di sisi lain, produksi skala besar menuntut efisiensi dalam klasifikasi dan penyortiran, yang saat ini masih dilakukan secara manual. Pengamatan visual yang dilakukan oleh pekerja sering kali menimbulkan inkonsistensi akibat kelelahan dan perbedaan persepsi. Selain itu, kebutuhan tenaga kerja yang besar untuk penyortiran manual dapat meningkatkan biaya operasional, sehingga metode manual ini kurang efektif [5].

Dalam konteks penelitian terung, telah diperoleh beberapa referensi pada penelitian sebelumnya, yang pertama adalah sistem yang dirancang untuk mengklasifikasikan berbagai jenis terung dengan memanfaatkan fitur *Hue, Saturation* dan *Value* (HSV) dan *Histogram of Oriented Gradients* (HOG) menggunakan metode *Support Vector Machine* (SVM). Hasil pengujian menunjukkan bahwa kombinasi fitur HSV dan HOG bersama metode ini mampu mencapai tingkat akurasi yang sangat tinggi, yaitu 96,75%, dalam mengenali jenis terung hijau dan terung ungu [6]. Lalu pengembangan sistem deteksi kemanisan semangka menggunakan *Gray Level Co-occurrence Matrix* (GLCM) untuk ekstraksi tekstur dan *Backpropagation Neural Network* (BPNN) untuk klasifikasi. Hasilnya, sistem mencapai akurasi 86% pada pelatihan dan 85,7% pada pengujian dengan jarak optimal 15 cm [7]. Kemudian penelitian menggunakan *Principal Component Analysis* (PCA) untuk mengurangi dimensi citra tomat dan BPNN untuk identifikasi kualitas tomat. Dengan dataset 30 citra, sistem mencapai akurasi 76,7% menggunakan konfigurasi tiga *hidden layer*, menunjukkan metode ini efektif meskipun dapat ditingkatkan [8]. Lalu, penelitian menggunakan pendekatan Jaringan Syaraf Tiruan (JST) dengan operasi morfologi untuk mengklasifikasikan kesegaran wortel berhasil mencapai akurasi 98,33% [9].

Selanjutnya pada penelitian pengembangan sistem untuk mengidentifikasi beras pemutih dan tanpa pemutih menggunakan jaringan syaraf tiruan *backpropagation*. Hasil penelitian menunjukkan akurasi sistem mencapai 90% pada laju pembelajaran 0,1 dan maksimum 1000 iterasi, dengan iterasi terkecil hanya 1 [10]. Kemudian penelitian menggunakan metode *backpropagation* untuk mengklasifikasikan kopi Arabika dan Robusta berbasis fitur citra digital dengan akurasi 72% pada data latih dan 85% pada data uji. Sistem berbasis matlab ini membantu petani mengklasifikasikan kopi lebih cepat dan akurat dibandingkan metode konvensional, dengan *precision* 85% dan *recall* 100% [11]. Terakhir, penelitian yang dilakukan menggunakan algoritma BPNN untuk mengklasifikasikan tiga jenis ikan karang di Taman Nasional Bunaken berdasarkan fitur bentuk, tekstur, dan warna. Sistem mencapai akurasi pelatihan hingga 88,73% dan validasi hingga 80%, menunjukkan kinerja yang cukup baik meski perlu perbaikan stabilitas [12]. Berdasarkan hasil pengamatan terhadap metode yang

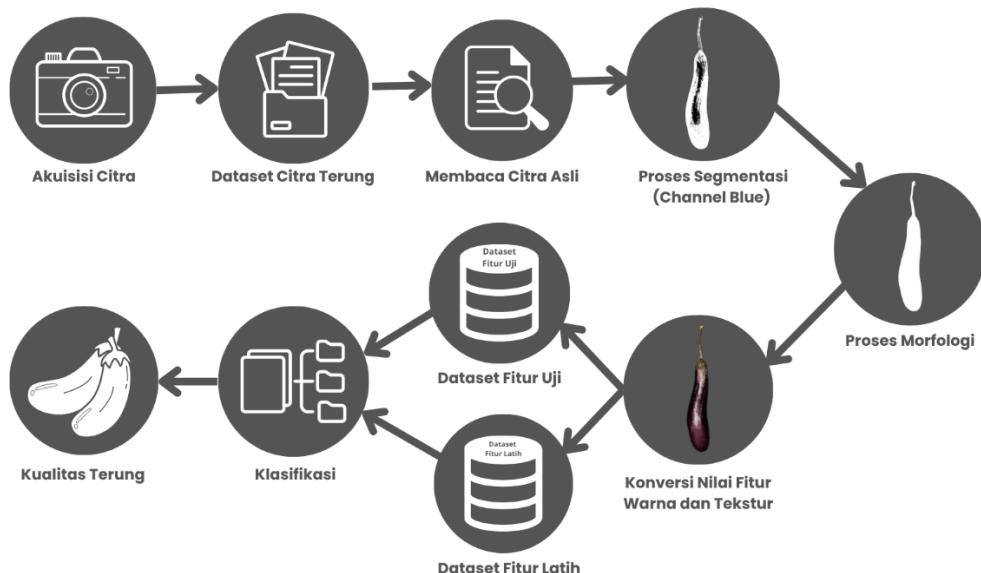
digunakan, Jaringan Syaraf Tiruan (JST) *Backpropagation* menunjukkan potensi besar untuk diterapkan dalam klasifikasi, karena kemampuannya yang efektif dalam menangani variasi fitur visual yang kompleks.

Namun, kendati telah ada penelitian terkait terung yang mengaplikasikan algoritma seperti SVM dan pengklasifikasian objek lain menggunakan BPNN Namun, hingga saat ini belum ada penelitian yang secara khusus memfokuskan pada penerapan algoritma *Backpropagation* untuk klasifikasi tingkat kualitas terung ungu dengan menggunakan fitur warna dan tekstur. Hal ini menunjukkan adanya celah yang perlu dieksplorasi lebih lanjut dalam penelitian guna mengembangkan sistem klasifikasi otomatis yang mampu menilai kualitas terung dengan lebih akurat.

Oleh karena itu, penelitian ini mengusulkan sistem klasifikasi tingkat kualitas terung dengan algoritma *backpropagation* berbasis fitur warna dan tekstur, dengan fokus penerapan objek terung yang diklasifikasikan ke dalam dua kelas utama yaitu kualitas baik dan kualitas buruk. Metode yang digunakan meliputi tahapan akuisisi citra, pengumpulan dataset, pembacaan citra asli, proses segmentasi, proses morfologi, ekstraksi nilai fitur warna dan tekstur, pelatihan dan pengujian data, dan pengklasifikasian. Setiap tahapan ini dipilih berdasarkan peran kritisnya dalam meningkatkan akurasi sistem klasifikasi. Dengan pendekatan otomatis ini, diharapkan dapat membantu mengatasi masalah inkonsistensi penilaian kualitas terung yang dilakukan secara manual, sehingga berkontribusi pada peningkatan daya saing produk hortikultura di Indonesia

II. METODE PENELITIAN

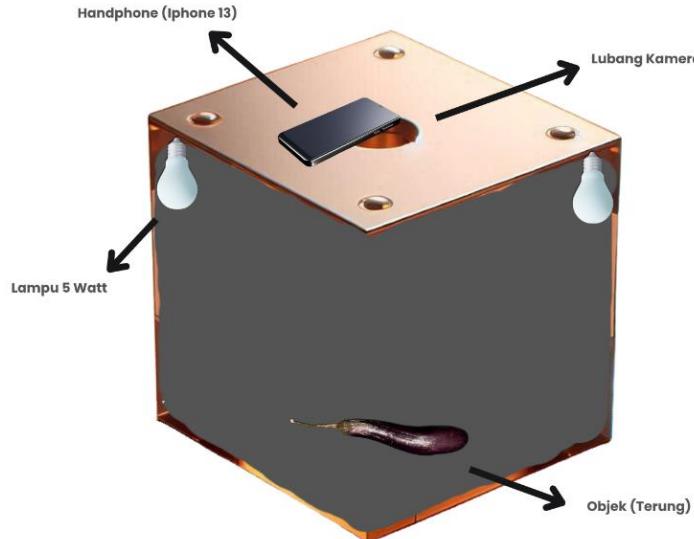
Metodologi yang digunakan dalam penelitian ini mencakup beberapa tahapan yang harus dilakukan secara berurutan, yaitu tahap akuisisi citra, pengumpulan dataset citra terung, pembacaan citra asli, proses segmentasi metode *otsu channel blue*, proses morfologi, ekstraksi nilai fitur warna dan tekstur, pelatihan dan pengujian data (90:10) dan pengklasifikasian objek terung. Tahapan-tahapan dapat dilihat secara rinci pada Gambar 1.



Gambar 1. Tahapan Metode

A. Akuisisi Citra

Pada tahap ini dilakukan proses pengambilan dataset citra Terung, dalam proses pengambilan citra menggunakan kamera *smartphone* iPhone 13 dengan pengaturan manual ISO 32, *focal length* 40 mm, *exposure time* 1/4 sec, F-Stop f/1.6, dan menggunakan *flash*. Selama proses pengambilan gambar, digunakan sebuah kotak berukuran 50 x 50 cm yang dilapisi kertas karton hitam sebagai latar belakang. Di dalam kotak ini juga terdapat tiga lampu untuk pencahayaan pada setiap sudut. Bagian atas kotak dilengkapi dengan lubang untuk menempatkan kamera, sehingga memudahkan pengambilan gambar objek di dalamnya. Kotak ini dirancang untuk menjaga konsistensi hasil gambar dengan mengurangi gangguan dari luar, seperti noise atau perubahan intensitas cahaya. Dengan menciptakan lingkungan pencahayaan yang terkontrol, masalah variasi kecerahan dapat diatasi dengan lebih efektif. Ilustrasi proses pengambilan gambar ini ditunjukkan pada Gambar 2.



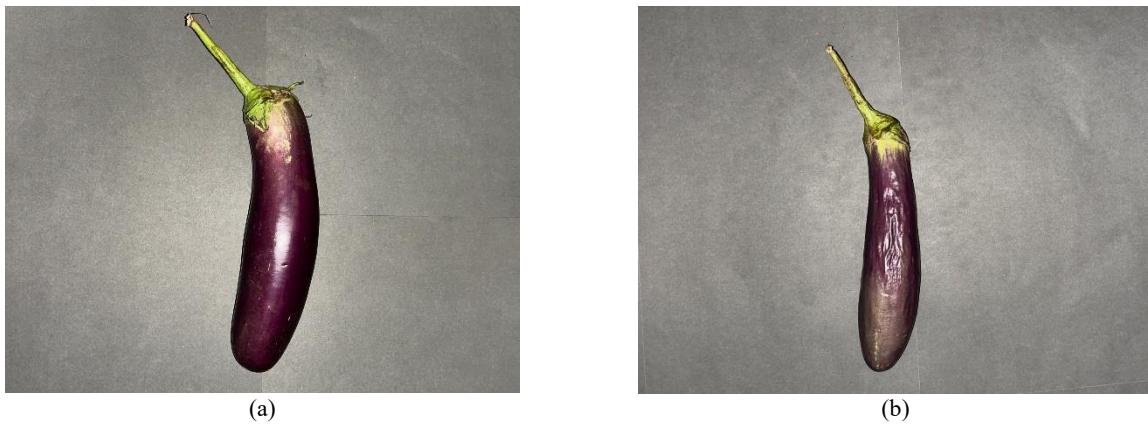
Gambar 2. Proses Pengambilan Citra

B. Dataset Citra Terung

Dataset yang dihasilkan dari proses pengumpulan citra objek terung dibagi menjadi dua kelas. Kelas ini mencakup 104 citra terung berkualitas baik, yang merepresentasikan terung dengan kondisi tanpa cacat fisik, ukuran sesuai standar, serta warna permukaan yang seragam. Sementara itu, citra terung berkualitas buruk terdiri atas 108 citra yang menggambarkan terung dengan cacat fisik, seperti kerusakan akibat serangga, deformasi bentuk, atau ukuran yang tidak memenuhi standar. Semua citra disimpan dalam format RGB dengan resolusi yang seragam.

C. Dataset Citra Terung

Proses membaca citra asli adalah tahap awal yang penting, di mana setiap gambar diambil dari direktori yang telah ditentukan. Gambar yang diambil memiliki format RGB (*Red-Green-Blue*), dengan setiap channel mewakili intensitas warna merah, hijau, dan biru pada tiap piksel [13]. Pada penelitian ini, file gambar akan diidentifikasi dengan ekstensi (.jpg) dari direktori *input*, kemudian memuatnya satu per satu untuk diolah. Pemilihan channel biru, yang dilakukan setelah gambar diambil, ialah langkah untuk mengisolasi informasi visual spesifik yang mungkin lebih terlihat pada *channel* tersebut dibandingkan *channel* merah atau hijau, tergantung pada karakteristik objek atau latar belakang yang dianalisis. Gambar 3 menampilkan contoh dataset kedua kelas.



Gambar 3. Citra Asli Terung (a) Baik dan (b) Buruk

D. Proses Segmentasi

Tahap segmentasi adalah langkah penting dalam pengolahan citra digital yang bertujuan untuk memisahkan objek utama dari latar belakangnya. Dalam sistem pengendalian gerakan berbasis pengenalan pola, proses segmentasi digunakan untuk

memisahkan objek dari latar belakang sebagai langkah penting dalam analisis citra [14]. Selain itu, mengklasifikasikan berbagai metode segmentasi citra, termasuk metode berbasis area dan metode berbasis tepi, yang menunjukkan pentingnya segmentasi dalam pengolahan citra [15]. Dalam penelitian ini, Tahap segmentasi berperan penting dalam pemrosesan citra digital, dengan fokus utama pada pemisahan objek dari latar belakang. Segmentasi dilakukan menggunakan channel biru dari ruang warna RGB, yang dipilih berdasarkan hasil observasi intensitas channel tersebut yang menunjukkan kontras optimal antara objek utama dan latar belakang pada dataset yang digunakan. Pemilihan channel biru bertujuan untuk meningkatkan akurasi segmentasi, karena perbedaan intensitas yang signifikan dalam *channel* ini memungkinkan identifikasi objek secara lebih tajam dan rinci, sekaligus mengurangi potensi gangguan dari elemen latar belakang.

Proses dilanjutkan dengan penerapan metode *thresholding Otsu* untuk membentuk citra biner. Metode ini berfungsi dengan menentukan nilai ambang batas optimal melalui perhitungan variansi antar kelas untuk objek dan latar belakang, menghasilkan pemisahan intensitas yang paling jelas berdasarkan histogram distribusi piksel. Hasil segmentasi ini berupa citra biner di mana objek utama tampil dalam intensitas maksimum (putih) dan latar belakang dalam intensitas minimum (hitam), sehingga citra siap untuk dianalisis lebih lanjut dengan ketepatan dan keakuratan yang lebih tinggi.

E. Proses Operasi Morfologi

Proses morfologi dalam penelitian ini melibatkan serangkaian langkah yang bertujuan untuk memperbaiki dan menyempurnakan citra biner hasil segmentasi, sehingga objek yang diinginkan menjadi lebih jelas dan terisolasi dengan baik. Tahap pertama ialah penerapan operasi *closing*, yang menggunakan struktur elemen berbentuk *disk* untuk mengisi celah-celah kecil dan menghubungkan bagian-bagian objek yang terpisah. Tujuan dari langkah ini adalah untuk meningkatkan koneksi objek yang telah tersegmentasi, sekaligus menutupi lubang-lubang kecil [16]. Setelah itu, operasi erosi dilakukan untuk mengurangi ukuran objek dengan menghapus piksel di tepi objek, yang berguna untuk mengurangi *noise* dan fragmentasi pada objek yang terhubung terlalu banyak [17]. Selanjutnya, *bwareaopen* diterapkan untuk menghilangkan objek-objek kecil yang ukurannya di bawah ambang tertentu, seperti objek dengan area < 3500 piksel, yang cenderung merupakan gangguan atau elemen yang tidak relevan dengan objek utama. Kemudian, operasi dilasi dilakukan untuk memperbesar objek yang tersisa, menyatukan bagian-bagian objek yang sah dengan menggunakan struktur elemen berbentuk *disk* yang lebih besar [16]. Setelah itu, *closing* kedua diterapkan untuk memperbaiki struktur objek yang telah diperbesar, memastikan bahwa bagian-bagian yang terpisah dapat digabungkan kembali. Proses dilanjutkan dengan erosi tambahan untuk memperhalus objek, mengurangi gangguan di tepi objek. Terakhir, operasi *filling* diterapkan untuk menutup lubang-lubang dalam objek utama, sehingga menghasilkan citra akhir yang lebih padat, halus, dan terdefinisi dengan baik. Citra yang telah diproses ini kemudian disimpan untuk digunakan dalam analisis atau proses citra lebih lanjut.

F. Proses Ekstraksi Fitur

Proses ekstraksi fitur bertujuan untuk mengidentifikasi dan mengambil atribut khas dari citra yang telah melewati tahap segmentasi dan operasi morfologi. Atribut-atribut tersebut meliputi informasi penting seperti warna dan tekstur yang menjadi ciri utama citra [18].

Dalam penelitian ini, proses ekstraksi fitur dimulai dengan melakukan segmentasi dan operasi morfologi untuk menghasilkan *mask* dari objek utama dalam citra. Citra asli diproses pada channel biru, kemudian dipisahkan menggunakan segmentasi *Otsu* untuk membuat citra biner. Selanjutnya, beberapa operasi morfologi, seperti *closing*, erosi, dan dilasi, diterapkan untuk membersihkan hasil segmentasi dari objek-objek kecil atau *noise* yang tidak diperlukan. Setelah melalui langkah ini, objek terbesar dalam citra diidentifikasi berdasarkan luas area, sehingga hanya objek utama yang dipertahankan. *Mask* yang dihasilkan kemudian digunakan untuk mengisolasi bagian objek utama, mempersiapkannya untuk ekstraksi fitur yang lebih spesifik. Proses ekstraksi fitur melibatkan pengukuran karakteristik tekstur dan warna. Citra diubah menjadi *grayscale*, lalu matriks *Gray-Level Co-occurrence Matrix* (GLCM) dihitung untuk memperoleh fitur tekstur seperti kontras, korelasi, energi, dan homogenitas. Fitur warna diambil dari bagian objek utama yang telah diisolasi dengan *mask* dalam citra berwarna, dan dihitung dalam berbagai ruang warna, termasuk RGB, HSV, dan LAB, untuk mendapatkan rata-rata setiap channel warna yang mencakup intensitas dan kecerahan. Semua data fitur ini kemudian disimpan dalam file Excel sebagai output, yang dapat digunakan dalam analisis klasifikasi kualitas atau tujuan analisis lainnya.

G. Pelatihan dan Pengujian Data

Penelitian ini melibatkan tahapan pelatihan dan pengujian data untuk mengembangkan model klasifikasi yang dapat membedakan kualitas terung menjadi dua kategori, yaitu "Baik" dan "Buruk". Dataset awal terdiri dari 212 citra, dengan distribusi 104 citra berkualitas baik dan 108 citra berkualitas buruk. Proses pelabelan kualitas terung dilakukan dengan pengamatan fisik dan visual, didasarkan pada pendapat distributor terung. Terung yang dikategorikan sebagai "Baik" memiliki warna cerah dan merata, tekstur lebih mulus dan segar, serta bebas dari kerusakan atau noda. Sedangkan terung yang "Buruk" memiliki warna pudar, tekstur layu, dan kerutan atau bekas kerusakan pada kulit.

Dari total 212 citra yang tersedia, 90% dialokasikan sebagai data pelatihan, yang terdiri dari 94 citra berkualitas baik dan 97 citra berkualitas buruk. Data latih ini digunakan untuk melatih model agar mampu mempelajari pola-pola visual yang relevan, seperti fitur warna dan tekstur, yang menjadi dasar klasifikasi. Sementara itu, sisa 10% dari dataset, terdiri atas 10 citra berkualitas baik dan 11 citra berkualitas buruk, digunakan sebagai data uji untuk mengevaluasi performa model. Pembagian dataset dilakukan secara acak untuk menghindari bias dan memastikan model dapat melakukan generalisasi dengan baik terhadap data baru. Dengan strategi ini, model diharapkan mampu mengenali pola-pola kompleks pada data uji secara akurat, sekaligus memvalidasi keandalan dan efektivitas sistem dalam klasifikasi kualitas terung secara otomatis. Tabel 1 menampilkan pembagian untuk kedua kelas citra terhadap dataset pelatihan dan pengujian data.

TABEL 1
PEMBAGIAN DATA PELATIHAN DAN PENGUJIAN

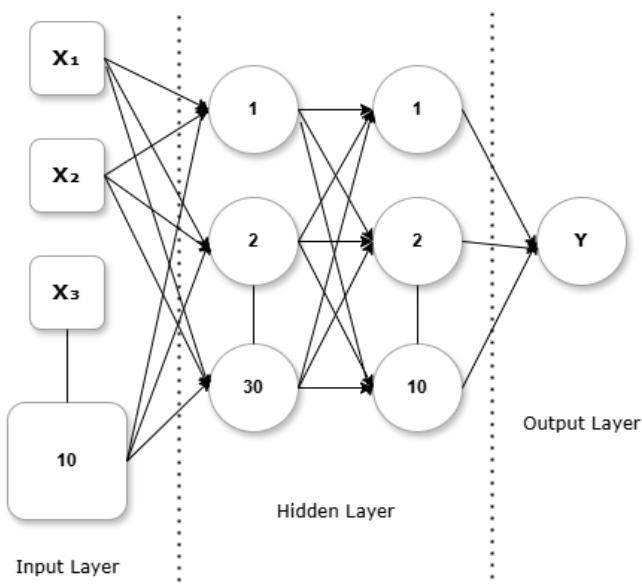
No	Kelas	Pelatihan	Pengujian	Total Citra
1	Baik	94	10	104
2	Buruk	97	11	108
Total		191	21	212

H. Proses Klasifikasi

Proses klasifikasi bertujuan untuk menilai kualitas terung, yaitu apakah terung termasuk dalam kategori baik atau buruk, dengan menggunakan fitur warna dan tekstur. Dataset yang telah melalui tahap segmentasi dan ekstraksi fitur kemudian dibagi menjadi dua bagian, yaitu data untuk pelatihan dan data untuk pengujian.

Algoritma *backpropagation feedforward* diterapkan sebagai metode utama dalam penelitian ini. Model ini terdiri dari tiga lapisan utama yaitu lapisan masukan, dua lapisan tersembunyi, dan lapisan keluaran. Pada lapisan masukan, terdapat tujuh *neuron* yang mewakili berbagai karakteristik hasil ekstraksi fitur. Di bagian lapisan tersembunyi, model menggunakan 10 *neuron* pada lapisan pertama dan 5 *neuron* pada lapisan kedua untuk mengolah informasi secara lebih mendalam. Sementara itu, lapisan keluaran hanya memiliki satu *neuron* dengan fungsi aktivasi linear yang bertugas menghasilkan output akhir [19].

Proses pelatihan model ini menggunakan algoritma *Levenberg–Marquardt* dilengkapi dengan dua lapisan tersembunyi beraktivasi *Rectified Linear Unit* (ReLU) yang masing masing terdiri dari 64 dan 32 neuron untuk mengatasi vanishing gradient. Lapisan pertama (64 neuron) dirancang untuk menangkap kompleksitas fitur warna dan tekstur terung, sedangkan lapisan kedua (32 neuron) mereduksi dan menyaring informasi menjadi representasi yang lebih ringkas sebelum diteruskan ke lapisan keluaran [20]. Pada lapisan keluaran, fungsi aktivasi *softmax* diterapkan untuk mengelompokkan data menjadi dua kategori yaitu baik dan buruk. Model ini dilatih selama 100 *epoch* dengan laju pembelajaran awal 0,001, yang ditetapkan melalui percobaan awal demi mencapai konvergensi yang stabil [21]. Untuk ilustrasinya dapat dilihat pada Gambar 4.

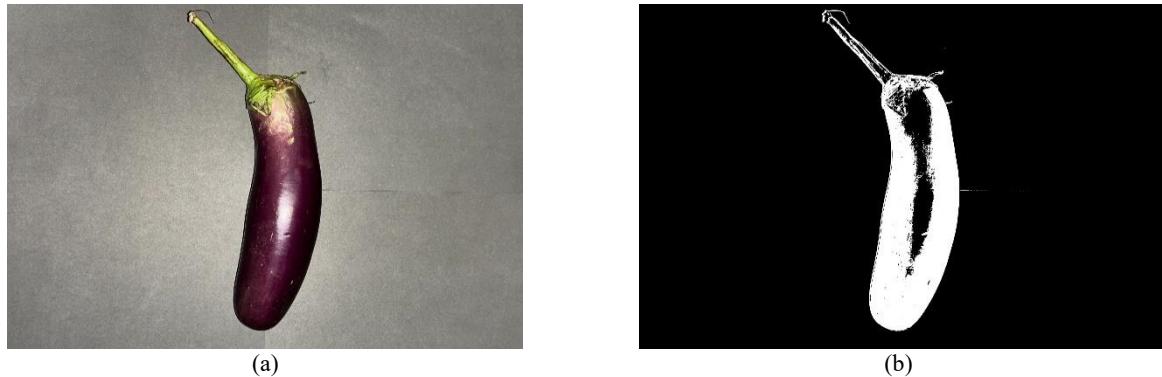


Gambar 4. Arsitektur Jaringan Syaraf Tiruan

III. HASIL DAN PEMBAHASAN

Pada penelitian ini, proses pengolahan citra digital dimulai dari tahap akuisisi hingga klasifikasi menggunakan kombinasi fitur warna dan tekstur. Tahapan-tahapan ini bertujuan untuk menciptakan model klasifikasi yang efektif dalam membedakan kualitas terung. Dalam proses analisis data, hasil setiap langkah pengolahan, seperti segmentasi citra, operasi morfologi, ekstraksi fitur, pelatihan dan pengujian, dan evaluasi kinerja model, memberikan wawasan mendalam tentang kontribusi masing-masing metode dan fitur terhadap akurasi klasifikasi.

A. Perbandingan Citra Asli dan Segmentasi



Gambar 5. Citra Terung (a) gambar asli dan (b) Segmentasi *Otsu Channel B*

Bisa dilihat pada Gambar 5, terdapat citra asli yang belum melalui proses segmentasi. Pada Gambar 5(a), objek dan *background* belum dipisahkan, sehingga keseluruhan piksel masih tampil sesuai dengan warna aslinya. Dengan citra asli ini, proses segmentasi nantinya akan memisahkan piksel-piksel yang tergolong objek dari piksel-piksel *background* berdasarkan perbedaan warna atau intensitas. Karena objek pada Gambar 5(a) memiliki warna yang lebih terang, metode *Otsu channel Blue* dapat memanfaatkan perbedaan ini untuk menghasilkan segmentasi yang akurat, memisahkan objek dari *background* secara optimal. Sedangkan Gambar 5(b) adalah hasil segmentasi.

B. Operasi Morfologi



Gambar 6. Tahapan Operasi Morfologi

Hasil segmentasi yang kurang optimal dapat mempengaruhi akurasi dalam ekstraksi fitur citra. Oleh karena itu, untuk memperbaiki hasil segmentasi dan meningkatkan kualitas ekstraksi fitur, dilakukan serangkaian operasi morfologi seperti yang ditampilkan pada Gambar 6. Prosedur morfologi ini sangat penting untuk mengisolasi objek utama dan menghilangkan gangguan yang dapat merusak analisis citra. Beberapa operasi morfologi yang digunakan dalam penelitian ini meliputi *closing*, *erosi*, *bwareaopen*, *dilasi*, dan pengisian lubang (*hole filling*). Setiap operasi tersebut dilakukan dengan menggunakan struktur elemen berbentuk disk yang berbeda-beda, disesuaikan dengan tujuan masing-masing operasi. Berikut adalah penjelasan dan rumus yang digunakan dalam masing-masing operasi morfologi:

- 1) *Closing*: Operasi *closing* digunakan untuk menutup celah kecil atau lubang pada objek yang seharusnya terhubung. Rumus *closing* didefinisikan pada persamaan (1).

$$A \cdot B = (A \oplus B) \ominus B \quad (1)$$

Di mana *A* adalah citra input dan *B* adalah struktur elemen (*disk radius 30 piksel*).

2) Erosi: Erosi berfungsi untuk menipiskan kontur objek dan menghilangkan noise kecil yang tidak diinginkan, mengurangi ukuran objek yang terhubung. Rumus erosi didefinisikan pada persamaan (2).

$$(A \ominus B)(x) = \min_{b \in B} A(x+b) \quad (2)$$

Di mana A adalah citra input, B adalah struktur elemen (*disk* radius 30 piksel), dan x adalah posisi piksel dalam citra.

3) *Bwareaopen*: Operasi *bwareaopen* digunakan untuk menghapus objek-objek kecil yang ukurannya di bawah ambang batas λ . Rumus *bwareaopen* didefinisikan pada persamaan (3).

$$\text{bwareaopen}(A, \lambda) = \bigcup_{i: |C_i| \geq \lambda} C_i \quad (3)$$

Dengan menghapus semua komponen terhubung berarea di bawah ambang λ ($\lambda = 3.500$ piksel), secara efektif menyaringkan noise berupa objek-objek kecil yang tidak relevan.

4) Dilasi: Dilasi digunakan untuk memperbesar objek dan menutup celah sempit. Rumus dilasi didefinisikan pada persamaan (4).

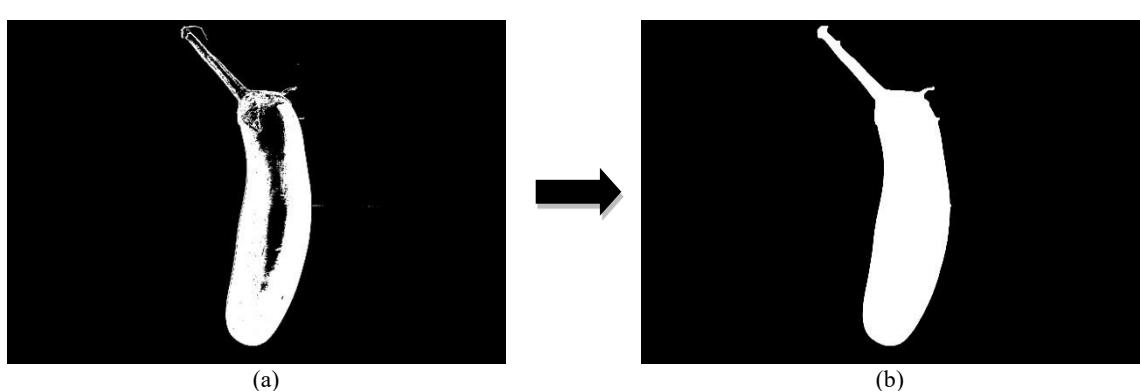
$$(A \oplus B)(x) = \max_{b \in B} A(x-b) \quad (4)$$

Untuk setiap piksel x , di sini digunakan *disk* ber-radius 30 piksel untuk memperbesar objek dan menutup celah sempit.

5) Pengisian lubang (*Hole Filling*): *Hole Filling* digunakan untuk menutup celah yang terdapat di dalam objek yang permukaannya sudah tertutup sepenuhnya, menghasilkan citra yang lebih padat dan terdefinisi dengan baik. Rumus *hole filling* didefinisikan pada persamaan (5).

$$\begin{aligned} H &= \text{rec}(A^C, M) \\ \text{lalu,} \\ \text{Filled} &= (H)^C \end{aligned} \quad (5)$$

Di mana A^C adalah komplemen dari citra A , dan M adalah parameter yang menentukan batas pengisian. Tahap ini akan menutup setiap lubang di dalam objek utama yang sudah terisolasi.

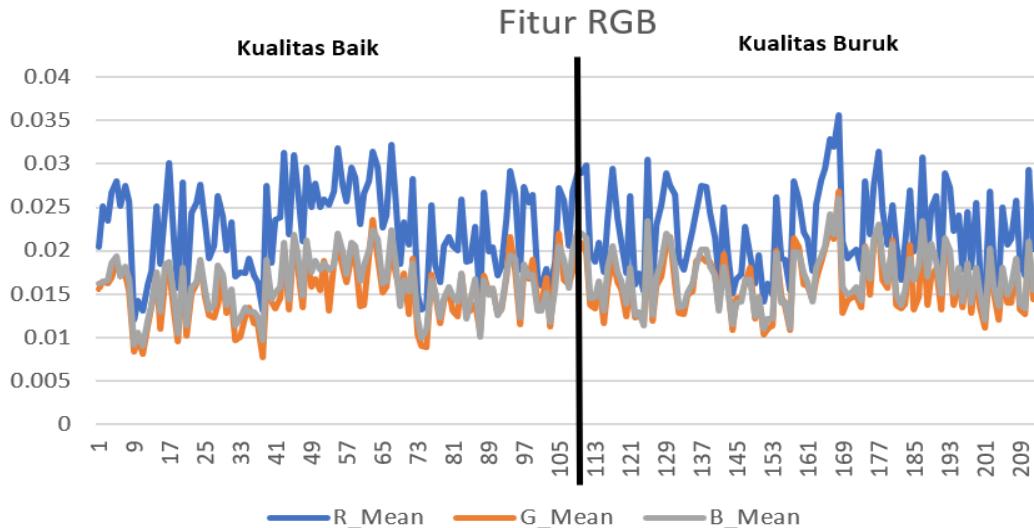


Gambar 7. Contoh citra hasil (a) Segmentasi ke (b) Morfologi

Selanjutnya, pada Gambar 7 terlihat perbedaan hasil segmentasi sebelum dan sesudah penerapan operasi morfologi. Pada Gambar 7(a), hasil segmentasi awal masih menunjukkan adanya *noise*, seperti objek kecil yang salah terdeteksi, serta beberapa piksel objek yang justru dianggap sebagai latar belakang. Setelah operasi morfologi diterapkan, sebagaimana ditampilkan pada Gambar 7(b), *noise* berupa objek kecil berhasil dihilangkan sepenuhnya, dan area objek yang sebelumnya terdeteksi sebagai latar belakang menjadi lebih kecil. Hasil ini menghasilkan segmentasi yang jauh lebih baik.

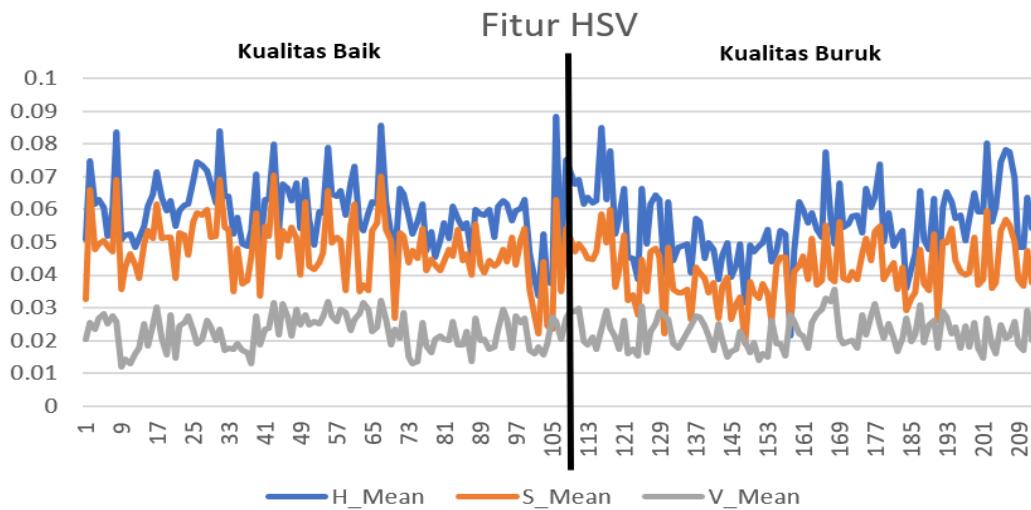
C. Hasil Ekstraksi Fitur

Setelah segmentasi yang akurat diperoleh, proses dilanjutkan ke tahap ekstraksi fitur, dimana fitur warna dipilih sebagai parameter utama. Pemilihan fitur warna ini didasarkan pada hasil uji coba beberapa skenario, yang menunjukkan bahwa fitur warna dalam ruang RGB, HSV, dan LAB memberikan akurasi yang sangat tinggi dibandingkan dengan kombinasi fitur lainnya. Ekstraksi fitur dilakukan dengan memanfaatkan parameter dari ketiga ruang warna tersebut.



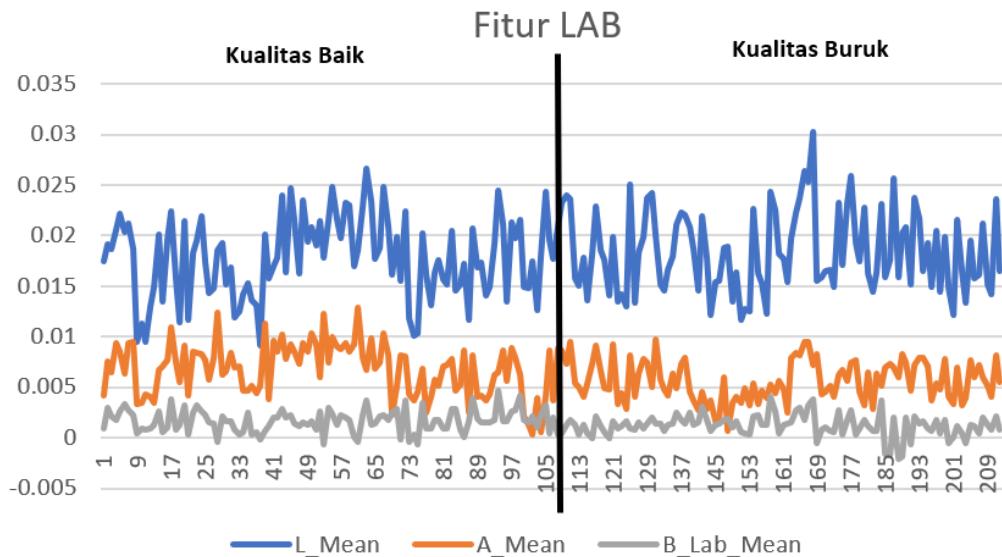
Gambar 8. Grafik Nilai Fitur Warna Channel RGB

Pada Gambar 8, menunjukkan nilai fitur dalam ruang warna RGB, terlihat bahwa intensitas channel R, G, dan B untuk kelas kualitas baik lebih tinggi dibandingkan kelas kualitas buruk. Fluktuasi yang terjadi pada kelas kualitas baik cenderung lebih konsisten dibandingkan dengan kelas kualitas buruk yang memiliki variasi intensitas lebih rendah. Grafik-grafik ini menunjukkan bahwa perbedaan intensitas warna dalam berbagai ruang warna dapat digunakan untuk membedakan antara kelas kualitas baik dan kualitas buruk.



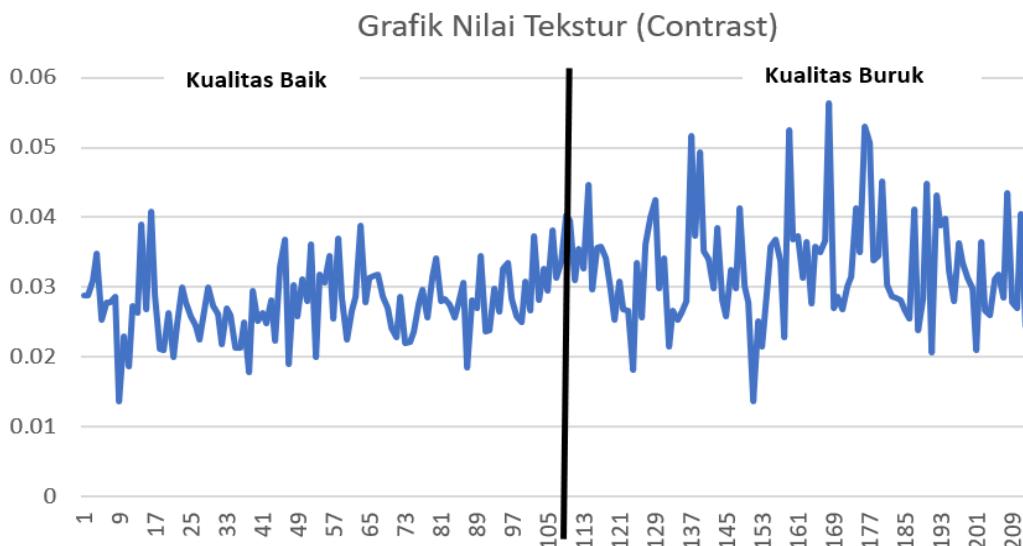
Gambar 9. Grafik Nilai Fitur Warna Channel HSV

Berdasarkan grafik pada Gambar 9, dapat dilihat bahwa terdapat perbedaan signifikan antara kelas kualitas baik dan kualitas buruk dalam intensitas channel H, S, dan V. Rata-rata intensitas pada kelas kualitas baik cenderung lebih tinggi dibandingkan dengan kelas kualitas buruk, yang terlihat dari fluktuasi nilai yang lebih rendah di grafik tersebut.



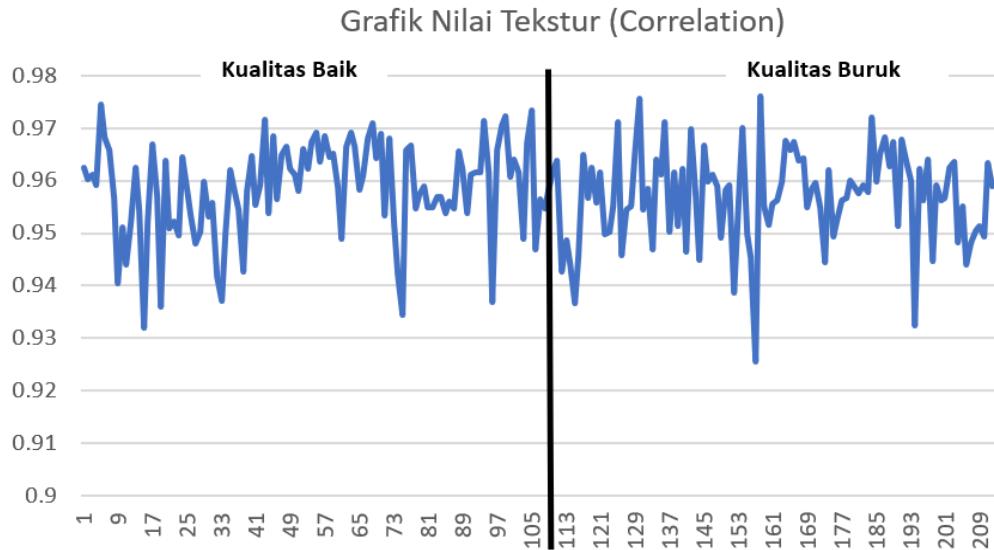
Gambar 10. Grafik Nilai Fitur Warna Channel LAB

Selanjutnya, Gambar 10 menunjukkan hasil ekstraksi fitur pada ruang warna LAB, di mana channel A pada kelas kualitas buruk cenderung lebih mengarah ke nilai negatif, yang menunjukkan dominasi warna hijau. Hal ini berbeda dengan kelas kualitas baik, yang memiliki nilai A lebih mendekati positif. Selain itu, pada channel L, intensitas kelas kualitas baik umumnya lebih tinggi dan stabil, sedangkan pada kelas kualitas buruk terlihat lebih rendah.



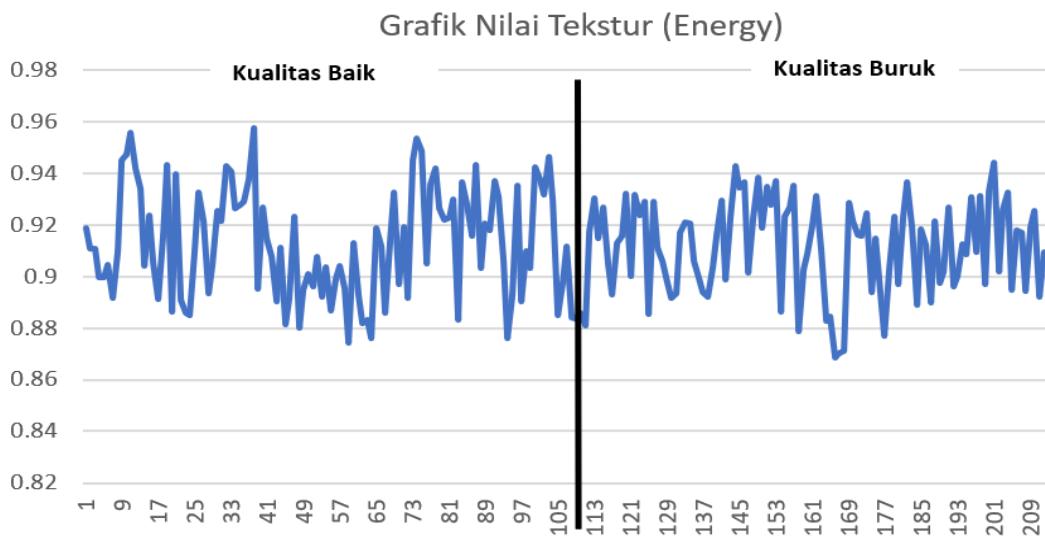
Gambar 11. Grafik Nilai Tekstur (Contrast)

Kemudian pada Gambar 11 menunjukkan perbedaan intensitas antara piksel yang berdekatan. Untuk kelas kualitas baik, nilai contrast cenderung lebih rendah dan stabil di kisaran 0.02 hingga 0.03. Ini menunjukkan bahwa permukaan terung berkualitas baik memiliki pola tekstur yang lebih seragam dan halus. Sementara itu, untuk kelas kualitas buruk, nilai *contrast* meningkat secara signifikan setelah titik pemisah (105), mencapai lebih dari 0.04 di beberapa sampel. Hal ini mengindikasikan adanya pola permukaan yang lebih kasar atau tidak seragam, yang khas pada terung dengan cacat fisik atau kerusakan.



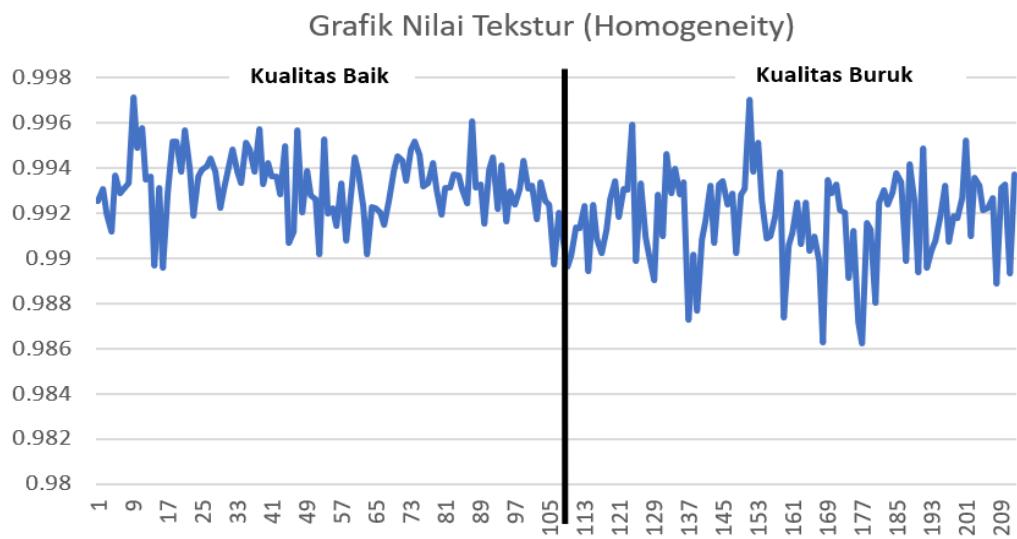
Gambar 12. Grafik Nilai Tekstur (Correlation)

Lalu pada Gambar 12 menunjukkan hubungan linier antara piksel-piksel dalam citra. Kelas kualitas baik memiliki nilai korelasi yang cenderung lebih tinggi, stabil di atas 0.95 hingga mendekati 0.97, yang menunjukkan distribusi tekstur yang konsisten. Sebaliknya, kelas kualitas buruk menunjukkan nilai korelasi yang lebih bervariasi dengan penurunan di beberapa titik, terutama setelah titik 105. Hal ini mencerminkan pola distribusi tekstur yang kurang teratur, kemungkinan akibat kerusakan atau ketidaksesuaian pola permukaan pada terung berkualitas buruk



Gambar 13. Grafik Nilai Tekstur (Energy)

Berdasarkan Gambar 13 grafik mencerminkan kekuatan pola tekstur dalam citra. Pada kelas Kualitas Baik, nilai *energy* umumnya lebih tinggi (di atas 0.90) dan stabil, menunjukkan bahwa permukaan terung dengan kualitas baik memiliki pola tekstur yang lebih teratur dan mendominasi. Sebaliknya, kelas Kualitas Buruk cenderung memiliki nilai *energy* yang lebih rendah, menunjukkan bahwa permukaan terung berkualitas buruk memiliki pola yang lebih acak atau tidak teratur, yang mengurangi energi tekstur secara keseluruhan



Gambar 14. Grafik Nilai Tekstur (*Homogeneity*)

Selanjutnya Gambar 14 menggambarkan tingkat keseragaman distribusi tekstur. Terung dengan kualitas baik menunjukkan nilai *homogeneity* yang sangat tinggi, stabil di atas 0,99. Hal ini mencerminkan tekstur yang halus dan seragam di seluruh permukaannya. Sebaliknya, meskipun nilai homogeneity pada terung berkualitas buruk tetap tinggi, grafiknya menunjukkan fluktuasi yang lebih besar dengan sedikit penurunan di beberapa titik. Ini mengindikasikan bahwa tekstur pada terung berkualitas buruk lebih bervariasi dan kurang seragam dibandingkan dengan yang berkualitas baik.

D. Pelatihan dan Pengujian

Setelah seluruh fitur berhasil diekstraksi, langkah berikutnya adalah melanjutkan dengan pelatihan dan pengujian menggunakan berbagai fitur. Tujuan utama dari tahap ini adalah untuk mengidentifikasi fitur yang paling optimal, yang tidak hanya menghasilkan akurasi tinggi, tetapi juga meminimalkan waktu yang dibutuhkan dalam proses tersebut.

TABEL 2
PERBANDINGAN ANTARA AKURASI DAN WAKTU KOMPUTASI PADA BERBAGAI FITUR

No	Kombinasi Fitur	Akurasi (%)		Recall		Precision		Waktu Komputasi (s)	
		Pelatihan	Pengujian	Pelatihan	Pengujian	Pelatihan	Pengujian	Pelatihan	Pengujian
1	RGB	74%	57%	74%	59%	78%	64%	16.269	0.274
2	HSV	77%	81%	77%	81%	78%	78%	1.173	0.007
3	LAB	74%	76%	74%	75%	75%	78%	0.705	0.006
4	Tekstur	80%	76%	80%	76%	80%	76%	0.853	0.006
5	LAB+RGB+HSV+TEKSTUR	92%	86%	92%	85%	92%	92%	2.183	0.004
	Rata-rata	79%	75%	79%	75%	81%	78%	4.237	0.059
	Tertinggi	92%	86%	92%	85%	92%	92%	16.269	0.274
	Terendah	74%	57%	74%	59%	75%	64%	0.705	0.004

Tabel 2 membandingkan kinerja berbagai kombinasi fitur dalam hal akurasi, *recall*, *precision*, dan waktu komputasi. Kombinasi fitur LAB+RGB+HSV+Tekstur memberikan hasil terbaik, dengan akurasi pelatihan mencapai 92% dan pengujian 86%, serta *precision* dan *recall* yang sama-sama tinggi (92% dan 85%). Selain itu, waktu komputasi kombinasi ini tetap efisien, hanya membutuhkan 2,183 detik untuk pelatihan dan 0,004 detik untuk pengujian. Sebaliknya, fitur RGB memiliki kinerja terendah, dengan akurasi pengujian hanya 57% dan *precision* pengujian 64%, meskipun waktu komputasinya jauh lebih lama untuk pelatihan (16,269 detik). Secara keseluruhan, rata-rata kinerja menunjukkan akurasi, *recall*, dan *precision* di kisaran 75-81%, dengan waktu komputasi yang cukup singkat untuk pengujian. Kombinasi fitur yang lebih kompleks ternyata mampu meningkatkan akurasi tanpa memperlambat waktu pemrosesan secara signifikan.

E. Pengklasifikasian

TABEL 3
HASIL KLASIFIKASI DATA LATIH LAB, RGB, HSV DAN TEKSTUR

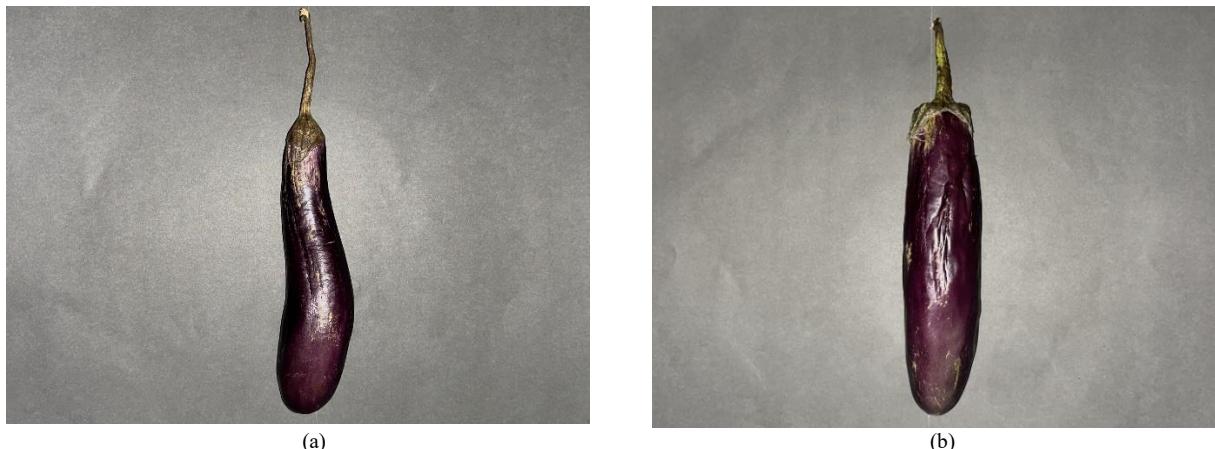
No	Kelas	Jumlah Sampel	Benar	Salah	Akurasi	ME
1	Baik	94	81	13	86,17	13,83
2	Buruk	97	94	6	96,91	3,09
Total		191	175	16	91,62	8,38

Berdasarkan Tabel 3, menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan data latih, dengan akurasi total sebesar 91,62% dan rata-rata kesalahan *Mean Error* (ME) sebesar 8,38%. Pada kelas "baik", dari 94 sampel, model berhasil mengklasifikasikan 81 sampel dengan benar, menghasilkan akurasi sebesar 86,17% dan ME sebesar 13,83%. Untuk kelas "buruk", model menunjukkan kinerja yang lebih baik, dengan 94 dari 97 sampel diklasifikasikan secara benar, menghasilkan akurasi 96,91% dan ME 3,09%. Secara keseluruhan, model lebih andal dalam mengenali kelas "buruk" dibandingkan kelas "baik," baik dari segi akurasi maupun tingkat kesalahan

TABEL 4
HASIL KLASIFIKASI DATA UJI LAB, RGB, HSV DAN TEKSTUR

No	Kelas	Jumlah Sampel	Benar	Salah	Akurasi	ME
1	Baik	10	7	3	70.00	30.00
2	Buruk	11	11	0	100.000	0.00
Total		21	18	3	85.71	14.29

Berdasarkan Tabel 4, menunjukkan hasil klasifikasi data uji dengan akurasi total sebesar 85,71% dan *Mean Error* (ME) sebesar 14,29%. Untuk kelas "baik", dari total 10 sampel, model berhasil mengklasifikasikan 7 sampel dengan benar, menghasilkan akurasi sebesar 70,00% dan ME sebesar 30,00%. Sementara itu, pada kelas "buruk", model mampu mengklasifikasikan seluruh 11 sampel dengan benar, mencapai akurasi sempurna sebesar 100,00% dan ME 0,00%. Hasil ini menunjukkan bahwa model memiliki performa yang lebih baik dalam mengenali kelas "buruk" dibandingkan kelas "baik," dengan tingkat kesalahan yang lebih tinggi pada kelas "baik".

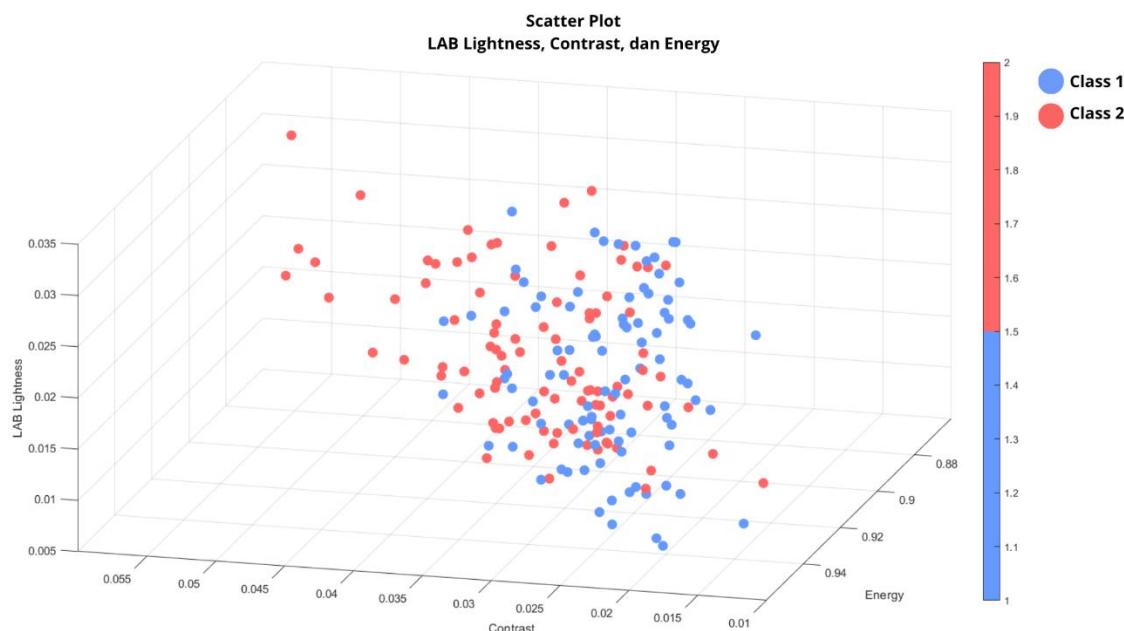


Gambar 15. Sampel Data Citra yang Salah Diklasifikasikan

Gambar 15(a) menunjukkan citra terung yang sebenarnya berkualitas baik, namun salah diklasifikasikan sebagai buruk (*False Negative*). Kesalahan ini disebabkan oleh beberapa ciri visual pada permukaan terung yang menyerupai karakteristik kelas "buruk". Permukaan terung yang memiliki kerutan halus, dan pencahayaan yang tidak merata, terutama di area tengah dan pangkal, yang memengaruhi nilai fitur teksturnya, seperti *contrast* dan *energy*, membuat citra ini menyerupai pola yang umumnya ditemukan pada terung berkualitas buruk. Dalam hal ini, kontras merujuk pada perbedaan intensitas antara area terang dan gelap dalam citra, sementara energi menggambarkan seberapa homogen atau beragam tekstur dalam citra tersebut. Kedua fitur ini, diukur melalui *Gray-Level Co-occurrence Matrix* (GLCM), dan menjadi faktor yang menyebabkan model salah dalam mengklasifikasikan terung tersebut.

Selanjutnya, Gambar 15(b) menunjukkan citra terung berkualitas buruk, namun salah diklasifikasikan sebagai baik (*False Positive*). Kesalahan ini terjadi karena terung tersebut memiliki cacat fisik samar, yang sulit dikenali dalam citra akibat pencahayaan yang lebih baik. Pencahayaan yang lebih merata menyebabkan model lebih banyak mengandalkan fitur warna, khususnya dalam ruang warna LAB dan HSV, yang mengaburkan ciri-ciri cacat tersebut. Dalam ruang warna LAB, warna terung cenderung lebih terperinci dengan memisahkan luminositas (L), warna merah-hijau (A), dan warna biru-kuning (B), sedangkan dalam ruang HSV, yang lebih berfokus pada *hue* (warna), *saturation* (kejemuhan warna), dan *value* (kecerahan), citra ini terlihat lebih baik, yang menyebabkan model gagal mengenali cacat dan mengklasifikasikannya sebagai terung berkualitas baik.

Dengan demikian, *error* yang terjadi selama pelatihan dan pengujian ini disebabkan oleh fitur-fitur visual yang lebih menonjol, seperti tekstur dan perbedaan pencahayaan, yang mempengaruhi cara model menilai kualitas citra. Kesalahan klasifikasi ini menunjukkan bahwa pencahayaan yang tidak seragam dapat mengganggu fitur warna, terutama dalam ruang warna LAB dan HSV. Hal ini juga mengindikasikan bahwa model lebih menitikberatkan pada fitur yang lebih jelas atau dominan dari objek, seperti kerutan pada permukaan terung atau perbedaan warna, yang kemudian menjadi faktor dominan dalam pengambilan keputusan yang keliru.



Gambar 16. Grafik Scatter Plot (LAB Lightness, Contrast, dan Energy)

Berdasarkan Gambar 16 ditampilkan grafik *Scatter plot* dimana menampilkan distribusi dua kelas kualitas terung (*Class 1*: Kualitas Baik dan *Class 2*: Kualitas Buruk) berdasarkan fitur *LAB Lightness*, *Contrast*, dan *Energy*. Data *Class 1* cenderung terkonsentrasi pada nilai *lightness* yang lebih tinggi dan *energy* yang lebih stabil, mencerminkan permukaan terung yang lebih cerah dan tekstur yang teratur. Sebaliknya, data *Class 2* menunjukkan variasi yang lebih besar pada *contrast* dan *lightness*, menandakan permukaan yang lebih kasar atau tidak seragam. *Overlap* antara kedua kelas terjadi pada rentang *contrast* 0.015–0.025 dan *energy* sekitar 0.90–0.92, menunjukkan tantangan dalam pemisahan sempurna. Kombinasi fitur LAB+RGB+HSV+TEKSTUR menghasilkan akurasi pengujian 86%, dengan recall 85% dan *precision* 92%, menandakan bahwa model mampu mempelajari pola yang kompleks meskipun terdapat *overlap*.

IV. SIMPULAN

Melalui penelitian ini, diusulkan sistem klasifikasi otomatis untuk menilai kualitas terung dengan menggunakan pengolahan citra digital yang berfokus pada fitur warna dan tekstur. Proses mencakup akuisisi citra, segmentasi *Otsu Channel Blue* serta operasi morfologi untuk mengisolasi objek utama. Fitur tekstur diukur melalui *Gray-Level Co-occurrence Matrix* (GLCM), sedangkan fitur warna diekstrak dalam tiga ruang warna: RGB, HSV, dan LAB. Total *dataset* dibagi menjadi 90% untuk pelatihan dan 10% untuk pengujian, dengan model klasifikasi menggunakan jaringan saraf tiruan (JST) dan algoritma *backpropagation*. Hasil penelitian menunjukkan bahwa model mencapai akurasi pelatihan tertinggi sebesar 92%, dengan waktu komputasi rata-rata 2,183 detik per citra pada 191 citra latih. Dalam pengujian menggunakan 21 citra uji, model

mencapai tingkat akurasi sebesar 86%, dengan waktu komputasi rata-rata 0,004 detik per citra. Model menunjukkan efektivitas yang sangat tinggi dalam mengklasifikasikan terung berkualitas buruk, dengan akurasi sempurna (100%). Penelitian ini tidak hanya berkontribusi pada pengembangan teknologi penilaian kualitas sayuran, mengatasi masalah inkonsistensi dalam penilaian manual, tetapi juga membuka peluang untuk penelitian lebih lanjut dalam bidang pengolahan citra. Untuk kedepannya, sistem dapat dikembangkan lebih lanjut dengan mengoptimalkan ekstraksi fitur tekstur dan warna, melalui penerapan teknik peningkatan kontras, ekstraksi fitur spasial yang lebih kompleks, serta metode lanjutan seperti *Wavelet Transform* untuk menangkap informasi tekstur yang lebih mendalam. Pendekatan-pendekatan ini diharapkan dapat meningkatkan akurasi dan kinerja sistem dalam mengenali objek dalam dataset yang memiliki fitur sulit dibedakan.

UCAPAN TERIMA KASIH

Puji syukur dipanjangkan kepada Tuhan Yang Maha Esa atas rahmat-Nya, yang memudahkan penyelesaian penelitian ini. Terima kasih disampaikan kepada dosen, asisten dosen, teman-teman, serta semua pihak yang telah memberikan dukungan, bantuan, dan motivasi selama proses penulisan penelitian ini.

DAFTAR PUSTAKA

- [1] A. Al Fandi, R. Muchtar, and D. Notarianto, "Pengaruh Media Tanam terhadap Pertumbuhan Tanaman Terong (*Solanum melongena L.*) Dengan Sistem Hidroponik," 2020. [Online]. Available: <http://ejournal.urindo.ac.id/index.php/pertanian>
- [2] "statistik-hortikultura-2023", [Online]. Available: <https://www.bps.go.id/id/publication/2024/06/10/790c957ba8892f9771aeebf7/statistik-hortikultura-2023.html>
- [3] S. Jenderal -Kementerian Pertanian, "Statistics Of Food Consumption 2023 Pusat Data Dan Sistem Informasi Pertanian Center For Agricultural Data And Information System," 2023. [Online]. Available: <https://satudata.pertanian.go.id/details/publikasi/479>
- [4] C. Cesariana, F. Juliansyah, and R. Fitriyani, "Model Keputusan Pembelian Melalui Kepuasan Konsumen Pada Marketplace," *J. Manaj. Pendidik. Dan Ilmu Sos.*, vol. 3, no. 1, pp. 211–224, 2022.
- [5] W. Randa, M. I. Bustami, and W. Riyadi, "Perancangan Penyortir Kentang Berdasarkan Ukuran Menggunakan Load Cell Berbasis Arduino Uno," *J. Inform. Dan Rekayasa Komputer(JAKAKOM)*, vol. 4, no. 1, pp. 818–826, 2024.
- [6] A. B. Kurniawan and E. P. Widiyanto, "Klasifikasi Jenis Terung Menggunakan Metode SVM dengan Fitur HSV dan HOG," in *The 2nd MDP Student Conference 2023*,
- [7] Q. A'yun and F. Utaminingrum, "Rancang Bangun Deteksi Kemanisan Buah Semangka menggunakan Metode Gray Level Co-Occurrence Matrix dan Backpropagation Neural Network berbasis Raspberry Pi," *Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 2, pp. 707–712, 2022.
- [8] U. Murdika, Muhammad Alif, Yessi Mulyani, "Identifikasi Kualitas Buah Tomat dengan Metode PCA (Principal Component Analysis) dan Backpropagation," *Electrician*, vol. 15, no. 3, pp. 175–180, 2021.
- [9] D. Miftahul, J. Musdar, N. S. Eriyani, S. Azis, A. B. Kaswar, and S. Sasmita, "Implementasi jaringan saraf tiruan backpropagation untuk klasifikasi tingkat kesegaran wortel berbasis pengolahan citra digital disertai operasi morfologi," *JIPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1518–1533, 2024.
- [10] H. Ardiansyah and A. Witanti, "Identifikasi Beras Pemutih dan Beras Tanpa Pemutih Menggunakan Jaringan Syaraf Tiruan Backpropagation," *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 1, no. 1, pp. 191–203, 2021.
- [11] Riduan Syahri and Desi Puspita, "Application Of The Backpropagation Method For Digital Image Feature Extraction On Coffee Fruit Classification," *J. Informatics Telecommun. Eng.*, vol. 6, no. 2, pp. 494–505, 2023.
- [12] V. G. N. Mairi, L. A. Latumakulita, and D. T. Salaki, "Sistem Identifikasi Jenis Ikan Karang Lokal Taman Nasional Bunaken Menggunakan Metode Backpropagation Neural Network," *Konf. Nas. Ilmu Komput.*, pp. 307–311, 2021.
- [13] M. Z. Andrekha and Y. Huda, "Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan OpenCV Python," *Voteteknika (Vocational Tek. Elektron. dan Inform.*, vol. 9, no. 4, p. 27, 2021, doi: 10.24036/voteteknika.v9i4.114251.
- [14] N. J. Ramadhan, N. Lilansa, A. F. Rifa'i, and H. D. Nguyen, "Pattern recognition based movement control and gripping forces control system on arm robot model using LabVIEW," *J. Mechatronics, Electr. Power, Veh. Technol.*, vol. 13, no. 1, pp. 1–14, 2022.
- [15] H. Liu, "Image Segmentation Techniques for Intelligent Monitoring of Putonghua Examinations," *Adv. Math. Phys.*, vol. 2022, 2022, doi: 10.1155/2022/430266.
- [16] G. A. Trianto, F. J. Sinaga, M. F. Marzuki, and Q. Al Qorni, "Operasi Opening dan Closing pada Pengolahan Citra Digital Menggunakan Matlab," *Mdp Student Conf.*, pp. 104–110, 2022.
- [17] F. Maedjaja and Efraim, "Sistem deteksi teks pada cover buku dengan pendekatan karakter teks," *Infact Ukrim*, vol. 6, no. 2, 2021.
- [18] D. Satria Yudha Kartika and H. Maulana, "Preprosesing dan normalisasi pada dataset kupu-kupu untuk ekstraksi fitur warna, bentuk dan tekstur," *J. Comput. Electron. Telecommun.*, vol. 1, no. 2, pp. 1–8, 2021.
- [19] Solikhun and N. Amalya, "Algoritma Backpropagation Metode Levenberg Marquardt Dalam Memprediksi Penyakit Stroke," *Bull. Comput. Sci. Res.*, vol. 3, no. 2, pp. 191–196, 2023.
- [20] C. Chairati, N. Awalia, B. M. Jamaluddin, A. B. Kaswar, and S. Sasmita, "Klasifikasi Rasa Buah Salak Berdasarkan Warna Dan Bentuk Menggunakan Metode Jaringan Saraf Tiruan Berbasis Pengolahan Citra Digital," *JIPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1226–1235, 2024.
- [21] G. Zaida Mufligh, "Penentuan Parameter Pembelajaran Jaringan Saraf Tiruan Backpropagation dan Pengaruhnya Terhadap Proses Pelatihan," *J. Ris. Teknol. Inf. dan Komput.*, vol. 1, no. 2, pp. 12–17, 2021.