

KLASIFIKASI KANDUNGAN NUTRISI BUAH PISANG BERDASARKAN FITUR TEKSTUR DAN WARNA LAB MENGGUNAKAN JARINGAN SYARAF TIRUAN BERBASIS PENGOLAHAN CITRA DIGITAL

Wulandari¹, Sasmita², Musda Rida Mulia³, Andi Baso Kaswar*⁴, Dyah Darma Andayani⁵, Andi Sadri Agung⁶

^{1,2,3,4,5,6}Universitas Negeri Makassar, Makassar

Email: ¹wlndry.nurdin@gmail.com, ²sasmita.raca@gmail.com, ³musdaridamulia@gmail.com,
⁴a.baso.kaswar@unm.ac.id, ⁵dyahdarma@unm.ac.id, ⁶andisadriagung20@gmail.com

*Penulis Korespondensi

(Naskah masuk: 20 Desember 2023, diterima untuk diterbitkan: 13 Juni 2024)

Abstrak

Pisang (*musa spp.*) merupakan salah satu jenis buah yang tingkat produksinya selalu meningkat di setiap tahunnya, terutama di Indonesia. Hal ini dikarenakan pisang memiliki kandungan nutrisi yang berbeda di setiap kematangannya, sehingga dapat dikonsumsi oleh semua tingkatan usia sesuai kebutuhan nutrisinya. Namun, kebanyakan orang sulit menentukan kematangan pisang yang sesuai dengan kebutuhan nutrisi mereka karena memerlukan uji laboratorium yang memakan waktu dan peralatan canggih. Sebelumnya, telah dilakukan penelitian mengenai klasifikasi kematangan buah pisang, namun belum ada yang berfokus pada klasifikasi kandungan nutrisinya. Selain itu, diperlukan penambahan fitur lain guna meningkatkan akurasi klasifikasi. Oleh karena itu, penelitian ini mengusulkan sistem klasifikasi kandungan nutrisi buah pisang berdasarkan fitur tekstur dan warna LAB menggunakan jaringan syaraf tiruan berbasis pengolahan citra digital. Metode yang diusulkan tersebut terdiri atas enam tahap, diantaranya yaitu tahap akuisisi citra, *preprocessing*, segmentasi, morfologi, ekstraksi fitur, dan klasifikasi berdasarkan model yang telah dilatih. Selain itu, berbagai skenario pelatihan dan pengujian dilakukan untuk menemukan gabungan fitur yang memperoleh tingkat akurasi optimal, sehingga didapatkan dua kombinasi fitur terbaik yaitu fitur warna LAB dan fitur tekstur dimana yang diambil adalah nilai *contrast* dan *energy*. Berdasarkan hasil pengujian terhadap 100 citra uji, diperoleh rata-rata *precision* 98,18%, *recall* 98%, *F1-Score* 98,09% dan akurasi keseluruhan mencapai 98%. Berdasarkan hasil tersebut maka dapat disimpulkan bahwa metode yang diusulkan mampu mengklasifikasikan kandungan nutrisi buah pisang dengan tingkat akurasi yang tinggi.

Kata kunci: *pengolahan citra digital, nutrisi pisang, klasifikasi, jaringan saraf tiruan*

CLASSIFICATION OF THE NUTRITIONAL CONTENT OF BANANAS BASED ON TEXTURE AND COLOR FEATURES IN THE LAB AND USING ARTIFICIAL NEURAL NETWORKS BASED ON DIGITAL IMAGE PROCESSING

Abstract

Bananas (*Musa spp.*) are a type of fruit whose production levels always increase every year, especially in Indonesia. This is because bananas have different nutritional content at each ripeness, so they are safe for consumption by all age levels according to their nutritional needs. However, most people have difficulty determining the ripeness of bananas according to their nutritional needs because they need to carry out laboratory tests which take time and require sophisticated equipment. Previously, there was research that had classified the ripeness of bananas. However, no one has focused on classifying nutritional content, and it is necessary to add other measurement parameters to get more accurate classification results. Therefore, in this research a classification system for the nutritional content of bananas based on LAB texture and color features is proposed using artificial neural networks based on digital image processing. The proposed method consists of six stages, including image acquisition, *preprocessing*, segmentation, morphology, feature extraction and classification based on the trained model. Several training and testing scenarios were carried out to determine the feature combination that had the best level of accuracy. Based on the test results, two best feature combinations were obtained, namely texture features (*contrast* and *energy*) and LAB color. Based on the test results of 100 test images, the average *precision* is 98.18%, *recall* is 98%, *F1-Score* is 98.09%, and overall accuracy reaches 98%. Based

on these results, it can be concluded that the proposed method can classify the nutritional content of banana fruit with high accuracy.

Keywords: digital image processing, banana nutrition, classification, artificial neural networks

1. PENDAHULUAN

Pisang (*musa spp.*) merupakan salah satu jenis buah yang populer dikonsumsi secara global dan merupakan salah satu tanaman pangan utama setelah beras, gandum, dan jagung (Sirappa, 2022). Negara Indonesia sendiri termasuk salah satu produsen penghasil pisang terbesar di dunia, dengan produksi mencapai 9,24 juta ton pada tahun 2022 berdasarkan data dari Badan Pusat Statistik (BPS). Potensi produksi buah pisang di Indonesia mencakup wilayah yang luas, dan hampir seluruh bagian negara ini berperan sebagai daerah produksi pisang (Dwivany et al., 2021). Oleh karena itu, kebanyakan penduduk Indonesia menjadikan buah pisang sebagai sumber pangan sehari-hari karena kandungan nutrisinya yang melimpah.

Pisang sebagai buah yang kaya nutrisi, cocok dikonsumsi oleh semua usia karena memiliki daging buah yang mengandung komposisi nutrisi paling banyak (Zahra et al., 2021). Komposisi nutrisi daging buah pisang sangat dipengaruhi oleh tingkat kematangannya (Pramono, 2020). Tingkat kematangan buah pisang dibagi menjadi lima tingkatan, di mana setiap tingkatan memiliki kandungan nutrisi yang berbeda (Zahra et al., 2021). Tingkat kematangan buah pisang tidak hanya mempengaruhi daging buahnya, tetapi juga karakteristik fisik dan kimiawi kulitnya. Pada proses pematangan buah pisang, terjadi perubahan fisiologis dan kimiawi, seperti daging buah menjadi lembut, transformasi pati menjadi gula, perubahan warna kulit dari hijau menjadi kuning, serta pembentukan rasa dan aroma (Pramono, 2020). Namun, sebagian orang masih belum memahami karakteristik buah pisang mana yang memiliki kandungan pati resisten tertinggi, kaya akan antioksidan, mengandung glukosa yang melimpah, atau yang memiliki kandungan mineral tinggi.

Dalam rangka untuk mengetahui nilai dari kandungan nutrisi pisang, diperlukan uji laboratorium yang memakan waktu dan memerlukan peralatan canggih. Akibatnya, sebagian besar orang kesulitan menentukan tingkat kematangan pisang yang sesuai dengan kebutuhan nutrisi mereka. Oleh karena itu, pemanfaatan teknologi citra digital dapat digunakan untuk menentukan kandungan nutrisi pada buah pisang, karena memungkinkan proses analisis melalui citra dari objek yang diteliti (Dijaya, 2023). Dengan memanfaatkan pengolahan citra digital, perubahan fisiologis yang terlihat pada kulit buah pisang dapat dianalisis untuk memprediksi kandungan nutrisinya.

Beberapa penelitian sebelumnya telah melakukan klasifikasi tingkat kematangan buah pisang menggunakan pengolahan citra digital dengan

berbagai metode, salah satunya menggunakan *K-Nearest Neighbors* (KNN) untuk mengklasifikasikan tujuh tingkat kematangan buah pisang berdasarkan fitur tekstur, dengan tingkat akurasi mencapai 88,89%. (Kosasih, 2021). Penelitian berikutnya masih menggunakan metode yang serupa untuk menentukan kematangan pisang berdasarkan jenis perlakuannya yang dibagi menjadi 3 kelas diantaranya: matang alami, matang karbit, dan matang karena *ethrel*, berdasarkan fitur ruang warna *Red, Green, Blue* (RGB) dan tekstur, dengan tingkat akurasi tertinggi mencapai 86,67% pada nilai k ($n_neighbors$) = 1 (Abdullah and Azrian, 2022). Selanjutnya, terdapat penelitian dengan metode yang berbeda, yaitu menggunakan Jaringan Syaraf Tiruan (JST) untuk mengklasifikasikan tingkat kematangan buah pisang pada ruang warna RGB yang dibagi menjadi empat kelas, dengan tingkat akurasi yang diperoleh mencapai 98,3% (Jusrawati, Fitri and Kaswar, 2021). Terdapat juga penelitian dengan menggunakan metode *Watershed* berdasarkan segmentasi warna *Hue, Saturation, Value* (HSV) untuk mengidentifikasi warna kulit pada citra buah pisang kelas sangat matang, yang menghasilkan tingkat akurasi mencapai 65% (Muktianto and Indriyani, 2022).

Selain itu, terdapat pula beberapa penelitian terkait klasifikasi jenis buah pisang yang menggunakan *Support Vector Machine* (SVM) untuk mengklasifikasikan jenis pisang berdasarkan citra warna, yang dibagi menjadi 2 jenis pisang, dengan tingkat akurasi yang diperoleh mencapai 89,86% (Amrozi et al., 2022). Berikutnya terdapat penelitian yang menggabungkan metode SVM dengan KNN untuk mengklasifikasikan jenis buah berdasarkan fitur warna, tekstur, dan bentuk yang dibagi menjadi 7 kelas. Hasil penelitian menunjukkan bahwa dalam SVM, akurasi terbaik diperoleh pada fitur warna mencapai 41,67%, sementara dalam KNN, akurasi tertinggi diperoleh pada fitur tekstur mencapai 58,33% dengan nilai k terbaik adalah 2 (Yana and Nafi'iyah, 2021).

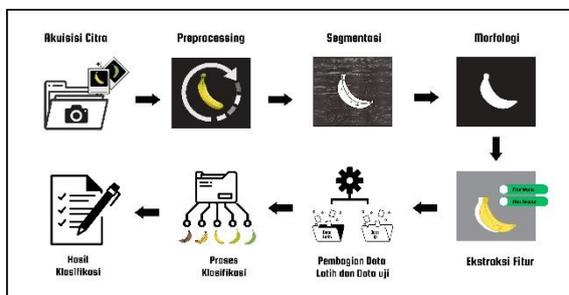
Terakhir, terdapat penelitian untuk mengidentifikasi pisang dan tingkat kematangannya menggunakan metode *JST Backpropagation*, berdasarkan fitur ruang warna RGB dan fitur bentuk (Widodo, Fauzi and Sembiring, 2023). Dalam proses pelatihan, buah pisang diklasifikasikan menjadi 5 kelas dengan tingkat akurasi mencapai 80%, sementara tingkat kematangan dibagi menjadi kelas matang dan tidak matang dengan akurasi mencapai 90%. Namun, dari beberapa penelitian tersebut, akurasi yang diperoleh untuk klasifikasi tingkat kematangan buah pisang masih kurang maksimal.

Selain itu, penelitian tersebut hanya berfokus pada kematangan buah pisang, belum ada yang mengklasifikasikan buah pisang berdasarkan kandungan nutrisinya. Parameter-parameter yang digunakan juga masih terbatas dan belum ada yang mencoba menggunakan fitur ruang warna seperti *Lightness*, *Green to Red*, dan *Blue to Yellow* (LAB).

Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengklasifikasikan kandungan nutrisi pada buah pisang berdasarkan fitur tekstur dan warna LAB dengan menggunakan metode JST berbasis pengolahan citra digital. Metode yang diusulkan terdiri dari enam tahapan, mencakup akuisisi citra, *preprocessing*, segmentasi, morfologi, ekstraksi fitur, dan klasifikasi berdasarkan model yang telah dilatih. Dengan menerapkan metode ini, akurasi dari proses klasifikasi dapat ditingkatkan, sehingga kandungan nutrisi buah pisang dapat diprediksi secara lebih akurat. Selain itu, penelitian ini juga bertujuan agar teknologi pengolahan citra digital dapat dimanfaatkan dalam pemilihan buah pisang berdasarkan dengan kebutuhan nutrisi yang diperlukan.

2. METODE PENELITIAN

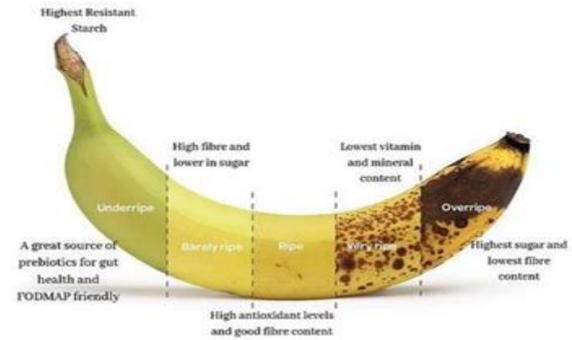
Metode penelitian ini melibatkan enam tahapan berturut-turut, diantaranya: akuisisi citra, *preprocessing*, segmentasi, morfologi, ekstraksi fitur, dan klasifikasi dengan model yang sudah dilatih. Ilustrasi tahapan metode terdapat dalam Gambar 1.



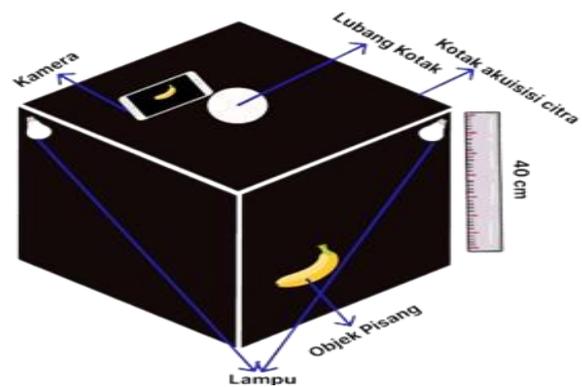
Gambar 1. Tahapan metode yang diusulkan

2.1 Tahap Akuisisi Citra

Tahap ini melibatkan pengumpulan dataset gambar atau citra pisang dengan cara mengonversi citra analog menjadi citra digital menggunakan kamera (Kaswar and Risal, 2020). Sebanyak 500 citra diakuisisi, dengan setiap kelas memiliki 100 citra. Lima kelas tersebut diambil berdasarkan kandungan nutrisinya yaitu Pati Resisten Tinggi, Glukosa & Antioksidan Rendah, Glukosa Sedang, Glukosa Tinggi dan Antioksidan Tinggi. Penilaian kandungan nutrisi pisang dilakukan secara visual dengan membandingkan karakteristik kulit pisang berdasarkan pada ilustrasi kandungan nutrisi pisang yang terdapat dalam Gambar 2.



Gambar 2. Ketersediaan nutrisi pada berbagai tingkat kematangan buah pisang (Zahra et al., 2021)



Gambar 3. Proses akuisisi citra

Pada Gambar 3, terlihat bahwa proses akuisisi citra dilakukan menggunakan sebuah kotak akuisisi citra yang dilengkapi dengan lampu di keempat sudut atasnya. Pada bagian atas kotak terdapat sebuah lubang untuk memungkinkan kamera mengakuisisi citra buah pisang di dalamnya. *Background* untuk citra buah pisang disediakan dalam bentuk kain berwarna hitam yang terletak di dalam kotak akuisisi. Saat proses akuisisi citra, digunakan kamera *smartphone* dengan spesifikasi dan pengaturan yang dapat dilihat pada Tabel 1. Semua pengaturan tersebut dilakukan agar hasil akuisisi citra tetap stabil dan tidak dipengaruhi oleh detail kecil seperti *noise* atau perubahan intensitas cahaya yang umumnya berubah secara relatif.

Tabel 1. Spesifikasi dan Pengaturan Kamera *Smartphone*

Spesifikasi	Keterangan
Resolusi Kamera	64 MP
Ukuran Gambar	3468 x 4624 Piksel
Zoom	Tanpa Zoom
Mode Flash	Tanpa Flash
Auto Fokus	Manual
Jarak Kamera	40 cm
<i>exposure value</i>	+0.17
ISO	200
White Balancing	4600K
Jarak Fokus	1/50 sec

2.2 Tahap *Preprocessing*

Setelah mengakuisisi citra digital dari buah pisang, maka tahap selanjutnya adalah tahap *preprocessing* yang bertujuan untuk meningkatkan kualitas citra yang dihasilkan sebelumnya

(Adenugraha, Arinal and Mulyana, 2022). Pada tahap ini, diterapkan proses *cropping* untuk memfokuskan citra pada area objek buah pisang. Setelah proses *cropping* berhasil, citra tersebut dimasukkan ke dalam program. Langkah berikutnya melibatkan penerapan skenario peningkatan kecerahan dan kontras pada citra, yang bertujuan untuk meningkatkan efektivitas saat proses segmentasi. Hasil dari skenario tersebut menunjukkan bahwa citra akan lebih efektif saat disegmentasi dengan penambahan kecerahan dan peningkatan kontras sebesar 10. Citra hasil penambahan kecerahan dan kontras dikonversi menjadi format RGB pada masing-masing channel warna (*red*, *green*, dan *blue*). Dalam penelitian ini, *channel red* yang terpilih untuk dijadikan acuan pada tahap segmentasi selanjutnya.

2.3 Tahap Segmentasi

Dalam tahap segmentasi, citra digital dipisahkan menjadi dua bagian yaitu bagian objek dan bagian *background* (Harjanti and Himawan, 2021). *Input* yang digunakan dalam tahap ini berupa citra *grayscale* dari *channel red* yang terpilih sebagai acuan proses segmentasi pada tahap sebelumnya. Metode yang diterapkan untuk segmentasi adalah metode *Otsu*, yang memanfaatkan nilai *threshold* (T) dari histogram citra *grayscale* untuk menentukan jumlah piksel dengan intensitas yang sama pada setiap intensitas (Firlansyah, Kaswar and Risal, 2021). Selanjutnya, diterapkan proses binerisasi untuk mengubah citra *grayscale* menjadi citra hitam putih (biner) menggunakan persamaan (1), dimana $g(x,y)$ adalah intensitas piksel pada koordinat (x,y) dalam citra hasil biner, dan $f(x,y)$ adalah intensitas piksel asli pada koordinat (x,y) dalam citra *grayscale*.

$$g(x,y) = \begin{cases} 0, & \text{jika } f(x,y) < T \\ 1, & \text{jika } f(x,y) \geq T \end{cases} \quad (1)$$

Melalui penerapan persamaan (1) di atas, diperoleh hasil citra biner, dimana objek memiliki nilai piksel 0 (hitam) dan *background* memiliki nilai piksel 1 (putih). Oleh karena itu, perlu dilakukan proses komplementasi karena tahap morfologi membutuhkan objek dengan piksel yang berwarna putih (Sholihah and Harjoko, 2021). Proses komplementasi citra biner dilakukan dengan menggunakan persamaan (2), dengan Y adalah nilai piksel dalam citra biner hasil komplementasi, dan x adalah nilai piksel dalam citra biner asli.

$$Y = 1 - x \quad (2)$$

2.4 Tahap Operasi Morfologi

Tahap morfologi melibatkan penggabungan beberapa piksel dari area *background* ke dalam area objek, atau sebaliknya (Paraijun, Aziza and Kuswardani, 2022). Tujuan dari tahap ini yaitu untuk meningkatkan kualitas citra hasil segmentasi dalam mengidentifikasi objek dan *background* yang diteliti (Widodo, Fauzi and Sembiring, 2023). Berbagai operasi morfologi digunakan, termasuk *opening*,

closing, *hole filling*, dan terakhir *bwareaopen*. Operasi *opening* meliputi dua tahap yaitu *erosi* diikuti oleh *dilasi* (Rahmadwati, Razak and Huda, 2022). *Erosi* mengikis piksel objek dengan mengganti nilai setiap piksel dengan nilai minimum piksel tetangganya, sedangkan *dilasi* melakukan sebaliknya. *Closing* adalah kebalikan dari *opening* yang bertujuan untuk mengisi celah dalam objek serta menghubungkan objek yang terputus. *Hole filling* digunakan untuk menutupi celah yang ada di dalam area objek pada citra. Kemudian, *bwareaopen* digunakan untuk menghilangkan detail kecil atau komponen yang tidak penting yang masih ada, serta dapat menghaluskan kontur objek sehingga area objek yang dihasilkan lebih halus dan bersih. Pada proses *opening* dan *closing*, *strel* yang digunakan adalah *strel* jenis *disk* yang bernilai 15. Adapun untuk operasi *bwareaopen*, parameter yang digunakan adalah 80000 piksel, dimana sistem akan menghilangkan objek lain yang memiliki luas kurang dari 80000 piksel, sehingga hasil segmentasi antara objek dan *background* menjadi lebih bersih.

2.5 Tahap Ekstraksi Fitur

Setelah tahap morfologi, langkah berikutnya adalah ekstraksi fitur, dimana nilai fitur diambil dari citra yang telah bersih dari hasil morfologi. Dalam penelitian ini, perbedaan antar kelas didasarkan pada fitur warna dan tekstur. Fitur warna yang akan digunakan adalah nilai dalam ruang warna LAB dengan menghitung nilai piksel *channel* masing-masing dari objek citra. Kemudian di setiap *channel* ditentukan nilai rata-rata pikselnya (*mean*). Sedangkan untuk fitur tekstur digunakan nilai *contrast* dan *energy* dari *Gray-Level Co-occurrence Matrix* (GLCM). *Contrast* adalah ukuran distribusi elemen matriks yang mempresentasikan perbedaan warna atau skala keabuan, dimana nilai yang semakin tinggi menunjukkan perbedaan warna atau skala keabuan yang semakin besar. Sementara itu, *energy* mengukur keseragaman dan disebut sebagai *angular second moment*, dengan nilai tinggi menunjukkan kemiripan piksel dan nilai rendah menunjukkan *heterogenitas* (Achmad, Yulfitri and Maharani, 2022). Untuk mencari nilai *contrast* dan *energy* dapat menggunakan persamaan (3) dan (4), dimana i sebagai baris matriks dan j sebagai kolom matriks. Adapun $P(i, j)$ merujuk kepada nilai elemen matriks kookurensi (GLCM) yang terletak pada baris (i) dan kolom (j) (Andono and Rachmawanto, 2021).

$$\text{Contrast} = \sum_{(i,j)} (i - j)^2 P(i,j) \quad (3)$$

$$\text{Energy} = \sum_{(i,j)} P(i,j)^2 \quad (4)$$

Hasil dari ekstraksi fitur ini digunakan sebagai nilai input untuk proses skenario klasifikasi data latih dan data uji berikutnya.

2.6 Tahap Klasifikasi

Setelah mendapatkan semua nilai fitur dari data latih dan data uji, langkah selanjutnya adalah

memasuki tahap klasifikasi. Pada tahap ini, dilakukan berbagai skenario berdasarkan hasil ekstraksi fitur dengan tujuan mencari kombinasi fitur yang optimal untuk membentuk *input* bagi model klasifikasi. Metode yang digunakan untuk membentuk model klasifikasi adalah JST dengan algoritma *Backpropagation*. Algoritma ini merupakan pembelajaran JST lanjutan yang dikembangkan dari aturan *perceptron*. Terdapat tiga tahapan dari algoritma ini yang meliputi *feedforward* yang diambil dari masukan *perceptron*, tahap penghitungan *backpropagation error*, dan pengaturan bobot (Murdika, Muhammad Alif, Yessi Mulyani, 2021). Dalam pembentukan model klasifikasi menggunakan metode ini, arsitektur jaringan harus dibangun terlebih dahulu.

Pada penelitian ini, jumlah *neuron* pada lapisan input yang digunakan sesuai dengan jumlah input yang paling optimal, yang diperoleh dari hasil skenario. Adapun arsitektur jaringan untuk penentuan *hyperparameter* seperti jumlah *layer*, jumlah *neuron*, jumlah *epoch*, dan fungsi aktivasi didasarkan pada arsitektur jaringan di penelitian terdahulu, karena telah terbukti optimal untuk mengklasifikasikan citra berdasarkan fitur-fitur warna dan tekstur (Agung et al., 2023). *Hidden layer* terdiri dari dua lapisan, di mana lapisan pertama memiliki 10 *neuron* dan lapisan kedua memiliki 5 *neuron*, dimana masing-masing menggunakan fungsi aktivasi *sigmoid*. *Output layer* terdiri dari 1 *neuron* dengan fungsi aktivasi *linear* untuk menentukan nilai kelas dari hasil klasifikasi, dan jumlah *epoch* adalah 1000. Setelah arsitektur jaringan terbentuk, jaringan dilatih menggunakan nilai fitur dari data latih, sehingga terbentuk model yang bisa digunakan untuk mengklasifikasikan citra *input* dari data uji.

2.7 Evaluasi

Evaluasi merupakan penilaian kinerja model untuk mengukur sejauh mana kemampuannya dalam mengklasifikasikan data dengan benar. Pada penelitian ini, digunakan *confusion matrix* untuk mengevaluasi kinerja model klasifikasi. *Confusion matrix* merupakan tabel yang mencatat jumlah kejadian antara klasifikasi aktual dan klasifikasi yang diprediksi (Grandini, Bagli and Visani, 2020). Terdapat empat jenis sel dalam *confusion matrix*, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP adalah jumlah observasi yang sesungguhnya berada dalam kelas positif, TN adalah jumlah observasi yang sebenarnya berada dalam kelas negatif, FP adalah jumlah observasi yang keliru diprediksi sebagai kelas positif, dan FN adalah jumlah observasi yang keliru diprediksi sebagai kelas negatif.

Dalam penelitian ini, beberapa metrik evaluasi dihitung menggunakan *confusion matrix*, termasuk presisi (*precision*), sensitivitas (*recall*), *F1-score*, dan akurasi (*accuracy*). *Precision* mengukur tingkat keakuratan model dalam mengklasifikasikan data

positif, *recall* mengukur kemampuan model dalam menangkap data positif, dan *F1-score* merupakan gabungan antara *precision* dan *recall*. Rumus perhitungan *precision* untuk setiap *class* dapat dilihat pada persamaan (5) dan rumus perhitungan *recall* dapat dilihat pada persamaan (6), dimana nilai *k* mewakili label dari kelas.

$$Precision_k = \frac{TP_k}{TP_k + FP_k} \quad (5)$$

$$Recall_k = \frac{TP_k}{TP_k + FN_k} \quad (6)$$

Dengan demikian, persamaan (7), (8) dan (9) dapat digunakan untuk menghitung rata-rata dari *precision*, *recall* dan *F1-Score*.

$$AverageP = \frac{\sum_{k=1}^k Precision_k}{k} \quad (7)$$

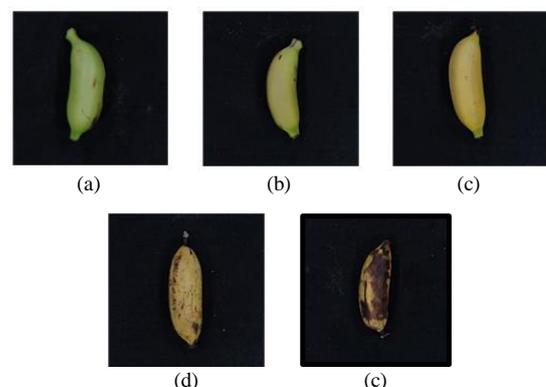
$$AverageR = \frac{\sum_{k=1}^k Recall_k}{k} \quad (8)$$

$$F1 - score = 2 * \left(\frac{AverageP * AverageR}{AverageP + AverageR} \right) \quad (9)$$

Akurasi mengukur tingkat keakuratan model dalam mengklasifikasikan seluruh data. Rumus Akurasi pada data kelas yang *balance* pada dasarnya adalah rata-rata dari *recall* (Grandini, Bagli and Visani, 2020). Selain itu, waktu komputasi juga diperlukan untuk menghitung durasi saat sistem menjalankan suatu proses.

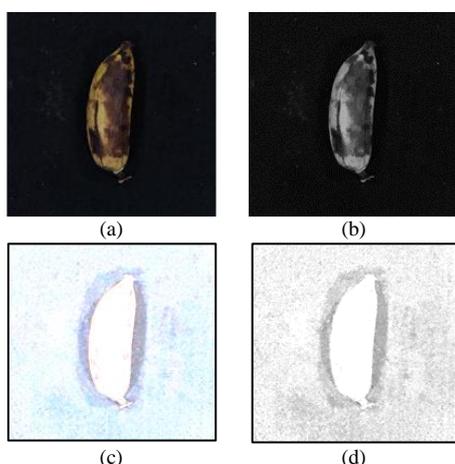
3. PEMBAHASAN

Penelitian ini diawali dengan melakukan pembagian 500 *dataset* citra buah pisang yang telah di-*cropping* ke dalam 5 kelas berdasarkan kandungan nutrisinya, yaitu Pati Resisten Tinggi, Glukosa & Antioksidan Rendah, Glukosa Optimal, Glukosa Tinggi dan Antioksidan Tinggi. *Dataset* citra kemudian dibagi menjadi dua, yaitu citra latih dan citra uji. Citra latih terdiri dari 80% dari total *dataset*, atau sebanyak 400 dengan 80 citra tiap kelas. Sementara citra uji terdiri dari 20% dari total *dataset*, atau sebanyak 100 citra dengan 20 citra disetiap kelasnya. Gambar 4 menunjukkan hasil akuisisi citra berdasarkan kelasnya.



Gambar 4. Citra kandungan nutrisi buah pisang (a) pati resisten tinggi, (b) glukosa & antioksidan rendah, (c) glukosa sedang, (d) glukosa tinggi dan (e) antioksidan tinggi

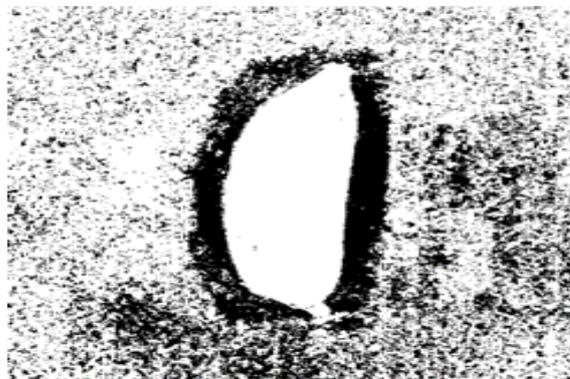
Perbedaan kandungan nutrisi pada buah pisang dari segi warna kulit dapat diamati dari Gambar 4. Pada Gambar 4(a) merupakan citra pisang Pati Resisten Tinggi dengan warna kulit keseluruhan berwarna hijau. Pada Gambar 4(b) merupakan citra pisang Glukosa & Antioksidan Rendah dengan warna kulit sudah mulai berwarna kekuning-kuningan. Gambar 4(c) merupakan citra pisang Glukosa Sedang dengan keseluruhan warna kulit berwarna kuning. Pada Gambar 4(d) merupakan citra pisang Glukosa Tinggi dengan warna kulit sudah terdapat berbintik-bintik coklat. Kemudian pada Gambar 4(e) merupakan citra pisang Antioksidan Tinggi yang ditandai dengan warna kulit kebanyakan berwarna coklat.



Gambar 5. Citra pisang (a) channel RGB, (b) channel R, (c) channel RGB + cahaya dan *contrast*, dan (d) channel R + cahaya dan *contrast*

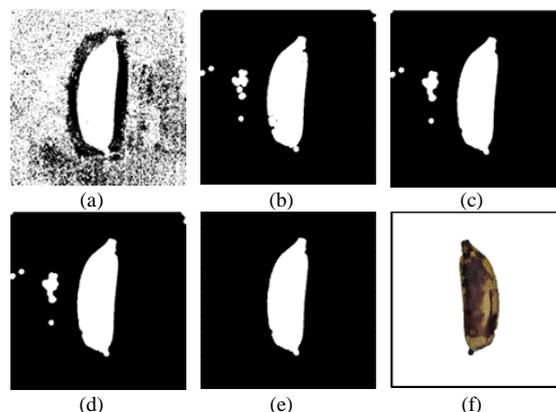
Untuk meningkatkan proses klasifikasi, citra terlebih dahulu diproses melalui tahap *preprocessing*, segmentasi dan operasi morfologi. Tahap *preprocessing* dilakukan dengan penambahan cahaya dan *contrast* bertujuan agar proses segmentasi di semua kelas tingkat kematangan buah pisang dapat dilakukan seoptimal mungkin. Untuk kelas pisang Pati Resisten Tinggi, Glukosa & Antioksidan Rendah dan Glukosa Sedang, dapat dihasilkan proses segmentasi yang optimal tanpa perlu dilakukan penambahan cahaya maupun *contrast*. Sementara itu, untuk citra kelas Glukosa Tinggi dan Antioksidan Tinggi, proses segmentasi kurang optimal apabila dilakukan tanpa penambahan cahaya dan *contrast*. Hal tersebut dapat dilihat pada Gambar 5(a) dimana citra pisang Antioksidan Tinggi memiliki warna yang hampir menyatu dengan warna *background*, sehingga apabila citra dikonversi ke *channel R*, akan sulit dibedakan antara objek dengan *background*, seperti yang terlihat pada Gambar 5(b). Oleh karena itu, dilakukan penambahan cahaya dan *contrast* pada citra RGB seperti yang ditunjukkan pada Gambar 5(c), lalu mengekstrak citra tersebut ke dalam *channel R* seperti yang ditunjukkan pada Gambar 5(d). Ekstraksi citra ke *channel R* ini dijadikan sebagai acuan pada proses segmentasi karena objek

dan *background* dipisahkan oleh tepi dan bayangan objek. Adapun hasil dari proses segmentasi menggunakan metode *Otsu* terdapat dalam Gambar 6.



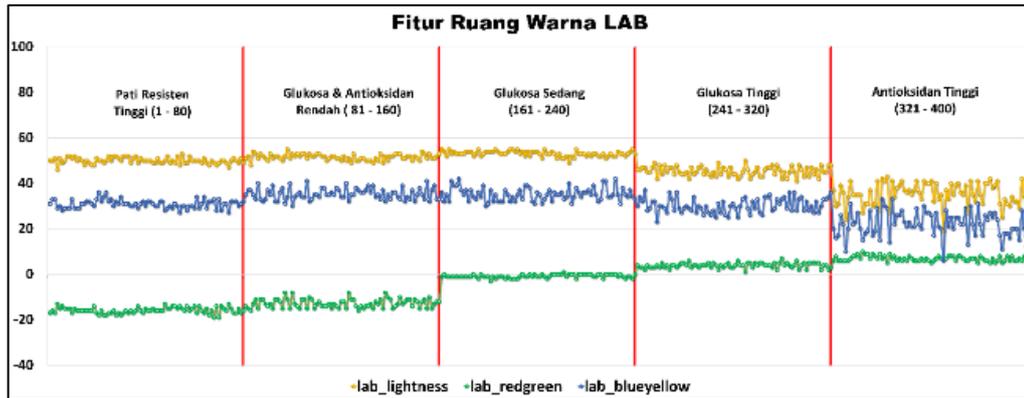
Gambar 6. Citra hasil segmentasi

Berdasarkan Gambar 6, hasil dari segmentasi menggunakan metode *Otsu* belum mampu mendeteksi area objek dan *background* dengan baik dikarenakan masih terdapat *noise* kecil pada *background* yang terdeteksi sebagai objek. Oleh karena itu, perlu dilakukan operasi morfologi sebagai tahap lanjutan agar bisa menghasilkan segmentasi yang lebih optimal. Gambar 7 menunjukkan hasil dari operasi morfologi.



Gambar 7. Citra hasil (a) segmentasi, (b) *opening*, (c) *closing*, (d) *hole filling*, (e) *bwareaopen* dan (f) segmentasi bersih RGB

Hasil segmentasi yang diperoleh pada Gambar 7(a) masih kurang optimal sehingga dapat menurunkan akurasi apabila hasil segmentasi tersebut digunakan untuk tahap ekstraksi fitur. Oleh karena itu, dilakukan operasi morfologi untuk menghasilkan citra segmentasi yang lebih bersih. Operasi morfologi dimulai dengan operasi *opening*, menghasilkan tampilan seperti yang terlihat pada Gambar 7(b). Pada Gambar 7(b), citra segmentasi tampak lebih bersih di area *background*, dikarenakan pada operasi *Opening*, dilakukan operasi *erosi* terlebih dahulu, sehingga *noise* kecil yang berwarna putih pada *background* akan mengecil, atau bahkan menghilang. Setelah operasi *erosi*, selanjutnya dilakukan operasi *dilasi*, sehingga bagian objek yang terkikis pada saat operasi *erosi* sebelumnya kembali ke ukuran yang normal.



Gambar 8. Grafik nilai fitur ruang warna LAB

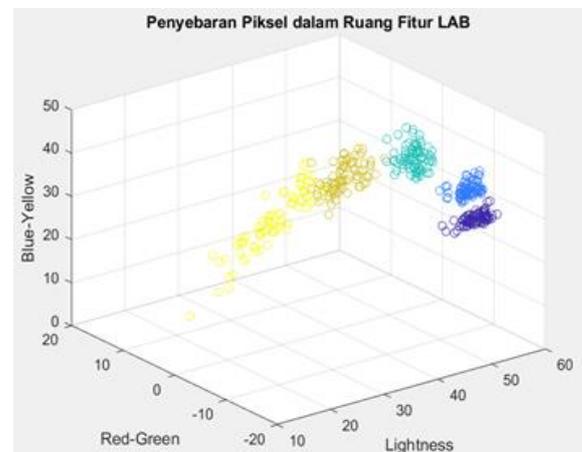
Namun efek dari operasi *opening* ini dapat mengakibatkan bagian-bagian objek terpisah.

Oleh karena itu, setelah proses *opening*, dilakukan operasi *closing* untuk menghubungkan bagian-bagian objek yang terpisah serta dapat memperhalus area tepi hasil segmentasi, seperti yang terlihat pada Gambar 7(c).

Proses selanjutnya melibatkan operasi *hole filling* untuk menutupi celah yang ada pada bagian objek. Hasil dari proses *hole filling* dapat dilihat pada Gambar 7(d). Namun, tidak terlihat perbedaan antara Gambar 7(d) dengan hasil operasi sebelumnya pada Gambar 7(c). Hal tersebut dikarenakan pada area objek yang memiliki lubang yang kecil, sudah ditutupi oleh operasi *closing*, sehingga pada tahap *hole filling* ini, tidak ada area objek yang perlu ditutupi. Operasi *hole filling* ini diperlukan untuk mengantisipasi apabila terdapat lubang besar pada area objek, yang tidak dapat ditutupi pada saat dilakukan operasi *closing*. Terakhir, tahap operasi morfologi ini ditutup dengan melakukan operasi *Bwareaopen* yang dapat dilihat pada Gambar 7(e). Operasi ini dilakukan untuk menghilangkan detail komponen yang tidak penting yang masih ada di sekitar objek seperti *noise* yang membesar di area *background* akibat operasi-operasi morfologi sebelumnya. Setelah hasil operasi morfologi selesai, didapatkan hasil segmentasi yang lebih bersih yang dapat mendeteksi area objek dan *background* lebih baik dan akurat. Hasil segmentasi bersih yang diterapkan pada citra RGB, yang terdapat pada Gambar 7(f).

Setelah segmentasi berhasil dilakukan dan teknik morfologi berhasil diterapkan, langkah selanjutnya adalah melakukan ekstraksi fitur. Terdapat dua jenis fitur yang dapat diekstraksi, yaitu fitur warna dan fitur tekstur. Proses ekstraksi fitur warna melibatkan parameter dari ruang warna LAB, sementara fitur tekstur diekstrak menggunakan parameter nilai *contrast* dan *energy* berdasarkan teknik GLCM. Visualisasi dari hasil ekstraksi fitur warna dapat dilakukan menggunakan grafik atau ruang tiga dimensi. Gambar 8 menunjukkan visualisasi dari hasil ekstraksi fitur dalam ruang warna LAB.

Ruang warna LAB mencerminkan seluruh warna yang dapat dilihat oleh mata manusia, dengan komponen L yang mengindikasikan tingkat kecerahan (*luminance*), komponen A menandakan posisi dari merah ke hijau, dan komponen B menunjukkan posisi antara kuning dan biru (Alamsyah and Pratama, 2019). Grafik pada Gambar 8 menggambarkan nilai L yang tinggi yang menunjukkan tingkat kecerahan yang lebih besar pada buah pisang Glukosa Sedang dibandingkan dengan pisang kelas Glukosa & Antioksidan Rendah dan Pati Resisten Tinggi. Akan tetapi, pada pisang kelas Glukosa Tinggi dan Antioksidan Tinggi, nilai L akan menurun dikarenakan pada kelas ini, buah pisang memiliki kulit berwarna kuning yang lebih gelap. Sementara itu, nilai A negatif menunjukkan adanya warna hijau yang lebih dominan pada kelas buah pisang Pati Resisten Tinggi dan nilai A positif menunjukkan adanya warna merah, yang dapat mengindikasikan warna kekuningan pada pisang. Adapun nilai B positif dapat menunjukkan adanya warna kuning pada buah pisang. Namun, nilai B akan menurun ketika kelas pisang Glukosa Tinggi dan Antioksidan Tinggi, menunjukkan adanya kandungan warna biru yang disebabkan oleh bintik-bintik cokelat pada kelas ini.



Gambar 9. Distribusi warna piksel LAB dalam ruang 3 dimensi

Visualisasi ruang 3 dimensi untuk penyebaran piksel pada fitur warna LAB, dapat ditemukan dalam Gambar 9. Distribusi piksel dalam ruang fitur pada Gambar 9, dapat diamati bahwa dalam ruang fitur

LAB, masing-masing kelas memiliki penyebaran yang terpisah, meskipun ada dua kelas yang memiliki penyebaran yang saling berdekatan. Dari pemaparan ruang warna LAB, dapat dibuat kesimpulan, bahwa ruang warna LAB dapat mengidentifikasi nutrisi yang terkandung di dalam buah pisang berdasarkan perubahan warna kulitnya. Kandungan pati dalam pisang bervariasi seiring tingkat kematangan (Bura, Ludong and Oessoe, 2023). Saat pisang belum matang yang memiliki kulit berwarna kehijauan, kandungan patinya akan lebih tinggi, sedangkan pada saat matang penuh yang memiliki warna kulit kekuningan, kandungan patinya menurun atau bahkan tidak ada. Selain itu, total kadar gula pada pisang juga dapat ditentukan berdasarkan warna kulitnya, dimana kadar gula akan meningkat saat kulit pisang mulai berwarna kuning.

Pisang yang memiliki warna kulit kehijauan memiliki kandungan senyawa fenolik yang lebih rendah dibandingkan dengan pisang yang memiliki warna kulit kekuningan. Senyawa fenolik pada pisang berperan sebagai antioksidan (Bashmil et al., 2021). Pada pisang yang mencapai tingkat kematangan sangat matang atau kelas Glukosa Tinggi, terjadi penurunan kualitas dan kandungan senyawa di dalamnya. Meskipun begitu, senyawa fenolik masih melimpah di dalam sel-sel kulit pisang, dan akan mengalami oksidasi yang menghasilkan pigmen melanin pada kulit pisang, memberikan warna kuning dengan bercak kecoklatan (Saputri and Augustina, 2020). Selain itu, seiring dengan meningkatnya tingkat kematangan buah pisang, kadar air yang terkandung dalam buah juga cenderung meningkat (Bura, Ludong and Oessoe, 2023). Ini menunjukkan variasi komposisi nutrisi dalam pisang tergantung pada tingkat kematangannya.

Oleh karena itu, dalam penelitian ini, kelas pisang Pati Resisten Tinggi memiliki pati resisten yang tinggi, sedangkan kadar gula, mineral, dan antioksidannya cenderung rendah. Pada kelas pisang Glukosa dan Antioksidan Rendah, memiliki kandungan gula yang rendah dan peningkatan kandungan mineral, yang dapat menyebabkan tekstur daging buah menjadi agak lembut. Adapun pada kelas pisang Glukosa Sedang, memiliki kandungan antioksidan, gula, dan mineral akan lebih tinggi dibandingkan dengan kelas pisang Glukosa & Antioksidan Rendah. Kemudian pada kelas pisang Glukosa Tinggi, memiliki kandungan gula yang lebih tinggi dan tingkat antioksidan yang lebih tinggi. Terakhir, kelas pisang Antioksidan Tinggi memiliki tekstur yang lunak dan rasa yang sangat manis karena kandungan gula tinggi, serta memiliki kandungan antioksidan yang tertinggi.

Pada Gambar 10, dapat dilihat hasil ekstraksi fitur *contrast* dan *energy*. Nilai *contrast* citra pisang pada masing-masing kelas menunjukkan nilai yang

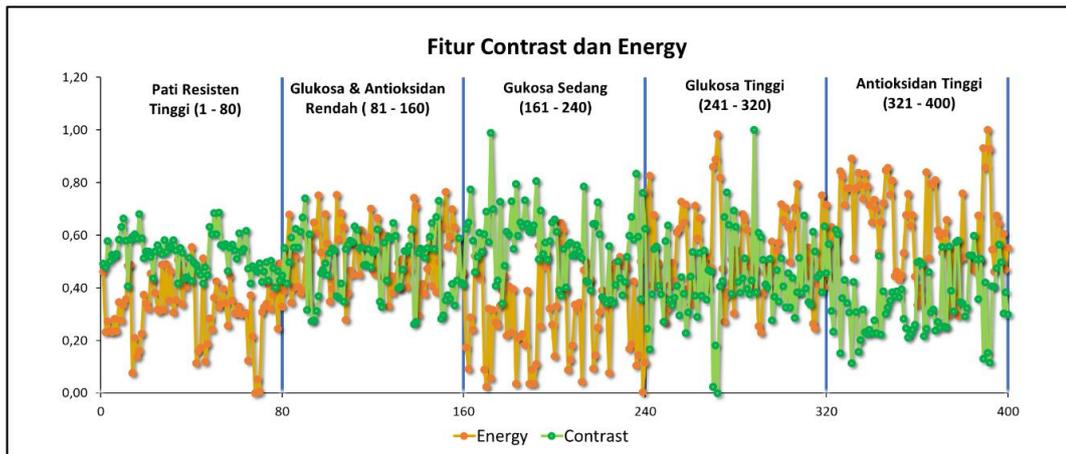
hampir stabil. Dilihat dari setiap titik tinggi rendahnya yang tidak berjauhan terutama pada kelas pisang Pati Resisten Tinggi. Ini membuktikan bahwa intensitas antara area terang dan gelap dalam citra pisang pada masing-masing kelas tidak berubah secara signifikan, sehingga dapat mempermudah klasifikasi. Adapun nilai *energy* pada masing-masing kelas menunjukkan grafik yang naik-turun secara signifikan. Grafik tersebut juga menunjukkan bahwa adanya perbedaan tingkatan nilai *energy* setiap kelas. Dapat diketahui bahwa *energy* mencerminkan tingkat keseragaman pada citra, dengan demikian semakin tinggi kesamaan antar citra, semakin tinggi juga nilai energinya (Wahyudi and Purwadi, 2020).

Berdasarkan hasil ekstraksi fitur, beberapa skenario percobaan dilakukan untuk mengklasifikasikan data latih dan data uji dengan kombinasi dari kedua fitur yang telah diekstraksi. Tujuannya adalah untuk menemukan kombinasi fitur terbaik yang menghasilkan tingkat akurasi pengklasifikasian tinggi dengan waktu komputasi yang paling efisien. Hasil dari skenario percobaan dapat dilihat pada Tabel 2.

Setelah membandingkan hasil *precision*, *recall*, akurasi dan waktu komputasi dari beberapa skenario, skenario yang terpilih adalah menggunakan fitur warna LAB dan fitur tekstur dengan parameter *contrast* dan *energy*. Pengujian LAB mendapat skor tertinggi dibandingkan dengan ruang warna lain seperti RGB dan HSV karena kemampuan LAB dalam merepresentasikan kecerahan warna (L) dan variasi warna melalui komponen A dan B. Ini memungkinkan untuk lebih mengenali variasi warna pada kulit pisang. Meskipun fitur ruang warna LAB memerlukan waktu komputasi yang relatif lebih lama dibandingkan dengan skenario lain, namun pada skenario ini menunjukkan kinerja unggul dengan akurasi mencapai 99,50% pada saat pelatihan dan 98,18% pada saat pengujian. Proses klasifikasi pada skenario ini melibatkan pelatihan model dengan menggunakan 400 citra latih. *Confusion matrix* dari hasil pelatihan terdapat pada Gambar 11.

		PREDIKSI				
		Pati Resisten Tinggi	Glukosa & Antioksidan Rendah	Glukosa Sedang	Glukosa Tinggi	Antioksidan Tinggi
AKTUAL	Pati Resisten Tinggi	80	0	0	0	0
	Glukosa & Antioksidan Rendah	0	80	0	0	0
	Glukosa Sedang	0	0	80	0	0
	Glukosa Tinggi	0	0	0	79	1
	Antioksidan Tinggi	0	0	0	1	79

Gambar 11. *Confusion matrix* pelatihan



Gambar 10. Grafik nilai fitur *contrast* dan *energy*

Tabel 2. Hasil Skenario Klasifikasi

Skenario	Precision		Recall		F1-Score		Akurasi		Waktu Komputasi	
	Latih	Uji	Latih	Uji	Latih	Uji	Latih	Uji	Latih	Uji
Warna RGB	98,24	98,18	98,25	98,00	98,24	98,09	98,25	98,00	43,27	9,42
Warna HSV	95,67	94,45	95,50	94,00	95,58	94,22	95,50	94,00	45,62	10,69
Warna LAB	98,49	98,18	98,50	98,00	98,49	98,09	98,50	98,00	99,42	21,45
RGB + Tekstur (<i>Contrast</i> + <i>Energy</i>)	99,53	98,18	99,25	98,00	99,39	98,09	99,25	98,00	60,38	14,81
HSV + Tekstur (<i>Contrast</i> + <i>Energy</i>)	93,51	90,51	93,00	90,00	93,25	90,25	93,00	90,00	67,25	16,78
LAB + Tekstur (<i>Contrast</i> + <i>Energy</i>)	99,50	98,18	99,50	98,00	99,50	98,09	99,50	98,00	109,97	27,09
RGB + Tekstur (<i>Contrast</i> + <i>Correlation</i> + <i>Energy</i> + <i>Homogeneity</i>)	98,77	96,66	98,75	96,00	98,76	96,33	98,75	96,00	68,22	14,95
HSV + Tekstur (<i>Contrast</i> + <i>Correlation</i> + <i>Energy</i> + <i>Homogeneity</i>)	97,33	86,58	97,25	86,00	97,29	86,29	97,25	86,00	68,59	17,65
LAB + Tekstur (<i>Contrast</i> + <i>Correlation</i> + <i>Energy</i> + <i>Homogeneity</i>)	99,71	96,66	99,25	96,00	99,48	96,33	99,25	96,00	111,68	27,22

Berdasarkan Gambar 11, dapat dilihat bahwa terdapat 400 citra latih yang dibagi menjadi 5 kelas yang berbeda, yang kemudian disajikan dalam bentuk *confusion matrix*. Dari Gambar 11 tersebut, didapatkan hasil klasifikasi citra dengan jumlah prediksi yang benar, yaitu 80 citra untuk masing-masing kelas Pati Resisten Tinggi, Glukosa & Antioksidan Rendah, dan Glukosa Sedang serta 79 citra untuk masing-masing kelas Glukosa Tinggi dan Antioksidan Tinggi. Dalam Gambar 11 juga terlihat bahwa prediksi untuk kelas Glukosa Tinggi dapat memprediksi ke kelas Antioksidan Tinggi begitu juga sebaliknya, dimana kelas Antioksidan Tinggi dapat memprediksi ke kelas Glukosa Tinggi.

Dengan demikian, dapat disimpulkan bahwa proses pelatihan berjalan cukup baik, dengan tingkat akurasi total mencapai 99,5%. Oleh karena itu, model JST yang telah dikembangkan dapat diterapkan untuk melakukan pengujian pada citra uji. Dengan melakukan pengujian menggunakan model JST yang telah dilatih, model tersebut berhasil mengklasifikasikan 100 citra uji dengan hasil pengujian yang disajikan dalam bentuk *confusion matrix* pada Gambar 12.

		PREDIKSI				
		Pati Resisten Tinggi	Glukosa & Antioksidan Rendah	Glukosa Sedang	Glukosa Tinggi	Antioksidan Tinggi
AKTUAL	Pati Resisten Tinggi	20	0	0	0	0
	Glukosa & Antioksidan Rendah	0	20	0	0	0
	Glukosa Sedang	0	0	20	0	0
	Glukosa Tinggi	0	0	0	20	0
	Antioksidan Tinggi	0	0	0	2	18

Gambar 12. *Confusion matrix* pengujian

Hasil *confusion matrix* pengujian pada Gambar 12, didapatkan rata-rata *precision* 98,18%, *recall* 98%, dan F1-Score 98,09% dengan akurasi keseluruhan mencapai 98%. Ini menunjukkan bahwa proses pengujian telah berjalan dengan sangat baik. Adapun pada kelas Glukosa Tinggi memiliki presisi sebesar 90%, yang berarti hanya terdapat dua prediksi yang salah pada kelas tersebut. Sementara itu, untuk kelas Antioksidan Tinggi nilai *recall* mencapai 90%, menunjukkan bahwa model mampu memprediksi kelas tersebut sebanyak 18 dari 20 citra.

4. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa algoritma JST *backpropagation* berhasil secara efektif dalam melakukan klasifikasi pada buah pisang berdasarkan kandungan nutrisinya. Dengan menggunakan fitur warna LAB dan fitur tekstur seperti *contrast* dan *energy*, pelatihan terhadap 400 citra latih menghasilkan tingkat akurasi, *precision*, *recall* dan *F1-Score* mencapai 99,5% dengan waktu komputasi 109,97 detik. Adapun hasil pengujian terhadap 100 citra uji, menunjukkan rata-rata *precision* 98,18%, *recall* 98%, *F1-Score* 98,09% dan akurasi keseluruhan mencapai 98% dengan waktu komputasi 27,09 detik. Dari hasil tersebut, maka nutrisi yang terkandung di dalam pisang dapat diklasifikasikan dengan baik. Adapun saran pengembangan dalam melakukan penelitian selanjutnya adalah disarankan untuk menggunakan kombinasi fitur serta metode klasifikasi yang berbeda agar dapat mempersingkat waktu komputasi.

DAFTAR PUSTAKA

- ABDULLAH, A. & AZRIAN, R., 2022. Identification of Barangan Banana Ripeness Treatment Types using k-Nearest Neighbor. *SISTEMASI: Jurnal Sistem Informasi*, 11(3), pp.761–774.
- ACHMAD, Y.F., YULFITRI, A. & MAHARANI, P., 2022. Penerapan Algoritma GLCM dan KNN dalam Pengenalan Jenis Jerawat. *Jurnal Komtika (Komputasi dan Informatika)*, 6(2), pp.74–82.
- ADENUGRAHA, S.P., ARINAL, V. & MULYANA, D.I., 2022. Klasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode KNN dan PCA Berdasarkan Citra RGB dan HSV. *Jurnal Media Informatika Budidarma*, 6(1), pp.9–17.
- AGUNG, A.S., SR, A.F.D., HERSYAM, M.S., KASWAR, A.B. & ANDAYANI, D., 2023. Classification of Tomato Quality Based on Color Features and Skin Characteristics Using Image Processing Based Artificial Neural Network. *Jurnal Teknik Informatika (JUTIF)*, 4(5), pp.1021–1032.
- ALAMSYAH, D. & PRATAMA, D., 2019. Segmentasi Warna Citra Bunga Daisy dengan Algoritma K-Means pada Ruang Warna Lab. *Jurnal Buana Informatika*, 10(2), pp.153–163.
- AMROZI, Y., YULIATI, D., SUSILO, A., NOVIANTO, N. & RAMADHAN, R., 2022. Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 11(3), pp.394–399.
- ANDONO, P.N. & RACHMAWANTO, E.H., 2021. Evaluasi Ekstraksi Fitur GLCM dan LBP Menggunakan Multikernel SVM untuk Klasifikasi Batik. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(1), pp.1–9.
- BASHMIL, Y.M., ALI, A., BK, A., DUNSHEA, F.R. & SULERIA, H.A.R., 2021. Screening and Characterization of Phenolic Compounds from Australian Grown Bananas and Their Antioxidant Capacity. *Antioxidants*, 10(10), pp.1–20.
- BURA, M.A.F., LUDONG, M.M. & OESSOE, Y.Y.E., 2023. Effect Of Maturity Level Of Kepok Banana (*Musa paradisiaca formatypica*) On Chemical And Organoleptic Properties Of Frozen Fried Banana. *Jurnal Agroekoteknologi Terapan*, 4(1), pp.191–198.
- DIJAYA, R., 2023. Buku Ajar Pengolahan Citra Digital. [online] Sidoarjo: Umsida Press. <https://doi.org/10.21070/2023/978-623-464-075-5>.
- DWIVANY, F., WIKANTIKA, K., SUTANTO, A., GHAZALI, F., LIM, C. & KAMALESHA, G., 2021. Pisang Indonesia. 1st ed. Bandung: ITB Press.
- FIRLANSYAH, A., KASWAR, A.B. & RISAL, A.A.N., 2021. Klasifikasi Tingkat Kematangan Buah Pepaya Berdasarkan Fitur Warna Menggunakan Jaringan Syaraf Tiruan. *Techno Xplore: Jurnal Ilmu Komputer dan Teknologi Informasi*, 6(2), pp.55–60.
- GRANDINI, M., BAGLI, E. AND VISANI, G., 2020. Metrics for Multi-Class Classification: an Overview. *ArXiv*, abs/2008.05756.
- HARJANTI, T.W. & HIMAWAN, H., 2021. Teknologi Pengolahan Citra Digital Untuk Ekstraksi Ciri pada Citra Daun untuk Identifikasi Tumbuhan Obat. *Faktor Exacta*, 14(3), pp.150–159.
- JUSRAWATI, J., FUTRI, A. & KASWAR, A.B., 2021. Klasifikasi Tingkat Kematangan Buah Pisang Dalam Ruang Warna RGB Menggunakan Jaringan Syaraf Tiruan (JST). *Journal of Embedded Systems, Security and Intelligent Systems*, 2(1), pp.49–54.
- KASWAR, A.B. & RISAL, A.A.N., 2020. Klasifikasi Tingkat Kematangan Buah Markisa Menggunakan Jaringan Syaraf Tiruan Berbasis Pengolahan Citra Digital. *Journal of Embedded Systems, Security and Intelligent Systems*, 01(1), pp.1–8.
- KOSASIH, R., 2021. Klasifikasi Tingkat Kematangan Pisang Berdasarkan Ekstraksi Fitur Tekstur dan Algoritme KNN. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 10(4), pp.383–388.
- MUKTIANTO, A. & INDRIYANI, V., 2022. Segmentasi Tingkat Kematangan Buah Pisang Cavendish Sangat Matang Berdasarkan Warna Menggunakan Watershed. *JURIKOM (Jurnal Riset Komputer)*, 9(1), p.148–151.
- PARAIJUN, F., AZIZA, R.N. & KUSWARDANI, D., 2022. Implementasi Algoritma Convolutional Neural Network Dalam

- Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah. *KILAT*, 11(1).
- PRAMONO, E.K., 2020. Pengukuran Tingkat Kematangan Buah Pisang Cavendish Berdasarkan Reflektansi Cahaya LED. *Jurnal Penelitian Pascapanen Pertanian*, 17(2), pp.88–94.
- RAHMADWATI, R., RAZAK, A.A. & HUDA, M., 2022. Operasi Morfologi dan Teknik Histogram pada Sistem Deteksi Plat Nomor Kendaraan Bermotor. *Jurnal EECCIS (Electrics, Electronics, Communications, Controls, Informatics, Systems)*, 15(3), pp.115–118.
- SHOLIHAN, N. & HARJOKO, A., 2021. Operasi Morfologi Dan Kode Rantai Untuk Menghitung Luas Area Basah Kertas Saring. *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 11(1), pp.1–12.
- SIRAPPA, M.P., 2022. Potensi Pengembangan Tanaman Pisang: Tinjauan Syarat Tumbuh dan Teknik Budidaya Pisang Dengan Metode Bit. *Jurnal Ilmiah Agrosaint*, 12(2).
- WAHYUDI, M. & PURWADI, H., 2020. Pengaruh Implementasi Seam Carving Pada Citra Berdasarkan Ciri Tekstur Menggunakan GLCM. *Edu Komputika Journal*, 7(1).
- WIDODO, D., FAUZI, A. & SEMBIRING, A., 2023. Identification of Banana Fruit Types Using the Backpropagation Method. *Journal of Artificial Intelligence and Engineering Applications (JAIEA)*, 3(1), pp.300–307.
- YANA, Y.E. & NAFI'YAH, N., 2021. Klasifikasi Jenis Pisang Berdasarkan Fitur Warna, Tekstur, Bentuk Citra Menggunakan SVM dan KNN. *Research: Journal of Computer, Information System & Technology Management*, 4(1), pp.28–36.
- ZAHRA, F., KHALID, S., ASLAM, M. & SHARMEEN, Z., 2021. Health Benefits of Banana (Musa)- A Review Study. *International Journal of Biosciences (IJB)*, 18(4), pp.189–199.

Halaman ini sengaja dikosongkan.