

Deteksi Otomatis Kelayakan Konsumsi Buah Pisang Menggunakan Multi Layer Perceptron (*MLP*)

Bima Putra Prasetya¹, Aliefiano Falent Rozza¹ Bagaskara²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri
E-mail: ¹bimaosd681@gmail.com, ²aliefianoguy@gmail.com

Abstrak – Buah pisang merupakan komoditas hortikultura penting di Indonesia yang tingkat kualitasnya sangat dipengaruhi oleh kematangan, sehingga diperlukan metode penilaian yang cepat dan objektif. Penilaian manual sering menimbulkan ketidakkonsistenan karena perbedaan persepsi visual antar penilai, sehingga memunculkan kebutuhan akan sistem deteksi otomatis yang lebih akurat. Penelitian ini bertujuan mengembangkan model klasifikasi untuk mendeteksi kelayakan konsumsi pisang berdasarkan citra digital menggunakan metode Multilayer Perceptron (MLP). Dataset yang digunakan berasal dari Banana Ripeness Image Dataset yang berisi empat kelas tingkat kematangan. Setiap citra diproses melalui tahapan preprocessing, kemudian diekstraksi fitur warnanya menggunakan ruang warna HSV dan fitur teksturnya menggunakan Grey Level Co-occurrence Matrix (GLCM), menghasilkan total 524 fitur sebagai input model. Data dibagi menjadi 80 persen data latih dan 20 persen data uji untuk memastikan proses evaluasi yang objektif. Hasil pengujian menunjukkan bahwa model MLP mampu mengklasifikasikan tingkat kematangan pisang dengan akurasi 98,99 persen disertai precision, recall, dan F1-score yang konsisten tinggi pada setiap kelas. Temuan ini menegaskan bahwa kombinasi HSV, GLCM, dan MLP merupakan solusi efektif untuk deteksi otomatis kelayakan konsumsi pisang yang dapat diterapkan dalam pemilahan buah pascapanen dan aplikasi pemantauan mutu.

Kata Kunci — GLCM, HSV, Klasifikasi, MLP, Pisang

1. PENDAHULUAN

Tanaman pisang atau yang dikenal dengan nama latin *Musa Paradisiaca* merupakan salah satu tanaman herba yang terdiri dari akar, batang, daun, dan buah[1]. Tanaman ini termasuk kedalam suku Musaceae, dapat tumbuh baik di dataran rendah maupun di dataran tinggi, sehingga tanaman ini banyak ditanam oleh masyarakat sebagai bahan pangan. Pisang memiliki tekstur yang lunak dan mudah dicerna oleh tubuh[2]. Pisang merupakan salah satu jenis buah yang populer dikonsumsi secara global dan merupakan salah satu tanaman pangan utama setelah beras, gandum, dan jagung[3].

Indonesia sendiri termasuk salah satu produsen penghasil pisang terbesar di dunia, pernyataan ini berdasarkan data dari Badan Pusat Statistik (BPS) dengan produksi mencapai 7,28 juta ton pada tahun 2019 dan mengalami peningkatan di 9,24 juta ton pada tahun 2022. Potensi produksi buah pisang di Indonesia mencakup wilayah yang luas, dan hampir seluruh bagian negara berperan sebagai daerah produksi pisang[4]. Pusat produksi pisang terdapat di beberapa wilayah yaitu di Jawa Barat (Sukabumi, Cianjur, Bogor), Jawa Tengah (Demak, Pati, Banyumas), Jawa Timur (Banyuwangi dan Malang), Sumatera Utara (Padangsidempuan, Tarutung), Sumatera Selatan (Ogan Komering Ilir), Lampung (Kayu Agung, Metro), Kalimantan, Sulawesi, Maluku, Bali, dan Nusa Tenggara Barat[5]. Indonesia dikenal sebagai salah satu pemasok pisang segar, dengan berbagai negara tujuan seperti Singapura, Cina, Arab, Australia, Amerika Serikat, dan beberapa negara lainnya. Sehingga kualitas pisang komoditi ekspor ini harus menjadi hal penting yang perlu untuk diperhatikan. Salah satu cara untuk mengetahui kualitas buah pisang yang baik adalah dengan melihat dari tingkat kematangan buah tersebut[6].

Waktu panen buah pisang umumnya ditentukan oleh kebutuhan ekonomi dan keamanan, bukan berdasarkan tingkat kematangan atau usia petiknya[7]. Kualitas buah pisang dalam penelitian ini dijelaskan melalui perubahan fisik, kimia, dan sensoris yang terjadi selama proses pematangan dan penyimpanan. Tingkat kematangan saat panen terbukti menjadi faktor utama yang menentukan mutu awal pisang, karena memengaruhi susut bobot, kadar air, dan pH buah. Pisang yang dipanen pada tingkat kematangan hijau-kuning memiliki kualitas paling baik, ditandai oleh kadar air yang stabil, susut bobot yang lebih rendah, serta keseimbangan karakteristik kimia seperti vitamin C, glukosa, lemak, dan protein. Lama penyimpanan juga memberikan pengaruh besar terhadap kualitas, terutama pada perubahan warna kulit yang diukur melalui nilai L, a, dan b, yang mencerminkan degradasi klorofil dan peningkatan pigmen karotenoid selama proses pematangan. Selain perubahan fisik dan kimia tersebut, aspek sensoris seperti warna visual, aroma, dan penerimaan keseluruhan oleh panelis menjadi indikator penting dalam menentukan mutu konsumsi. Penelitian ini menegaskan bahwa kualitas pisang tidak hanya bergantung pada kematangan visual, tetapi merupakan hasil interaksi kompleks antara tingkat kematangan awal


dan durasi penyimpanan, yang secara bersama-sama menentukan apakah buah tetap layak dikonsumsi, bernilai gizi baik, dan diterima oleh konsumen[8]

Banyak penelitian telah dilakukan dengan menggunakan metode dan algoritma berbeda untuk mengklasifikasikan kematangan pisang. Oleh karena itu, perlu dilakukan tinjauan sistematis terhadap berbagai metode dan algoritma yang diperlukan untuk mengklasifikasikan kematangan pisang guna memperoleh informasi yang lengkap mengenai keakuratan hasil dari beberapa metode yang dilakukan. Bandingkan dengan metode lain. Hal ini memunculkan ide-ide metode baru dan kombinasi metode untuk meningkatkan kualitas kebun lokal, khususnya pisang. Hal ini juga membantu memajukan ilmu pengetahuan di bidang pengkategorian kematangan buah untuk pertanian dan petani buah lokal.

2. METODE PENELITIAN

A. Tahapan Tahapan Metode

Untuk menghasilkan sistem deteksi otomatis kelayakan konsumsi buah pisang yang akurat dan dapat diandalkan, penelitian ini menerapkan serangkaian tahapan metode yang tersusun secara sistematis. Setiap tahap dirancang untuk memastikan bahwa citra yang digunakan memiliki kualitas yang memadai, fitur yang dihasilkan merepresentasikan karakteristik visual pisang dengan tepat, serta model yang dibangun mampu mempelajari pola kematangan secara efektif. Mulai dari pengumpulan data, pra-proses citra, ekstraksi fitur, hingga proses pelatihan dan evaluasi model, seluruh rangkaian metode disusun untuk membentuk alur kerja yang terpadu. Tahapan ini menjadi dasar dalam menghasilkan model klasifikasi berbasis *MLP* yang mampu mendeteksi tingkat kematangan pisang secara otomatis dengan performa evaluasi yang tinggi.



Gambar 1 . Diagram Alir Metode Penelitian

2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini berasal dari dataset publik berjudul “*Banana Ripeness Image Dataset*” yang dipublikasikan melalui repositori Telkom University Dataverse dengan DOI: 10.34820/FK2/GJBZ0X. Dataset ini berisi citra buah pisang dengan berbagai tingkat kematangan yang telah diberi label secara manual oleh pihak pengembang dataset. Dataset dapat diakses secara terbuka melalui tautan berikut: <https://bit.ly/banana-ripeness-dataset>. Pemilihan dataset ini dilakukan karena data telah terstruktur rapi, memiliki label kematangan yang lengkap, serta sesuai dengan kebutuhan penelitian yang berfokus pada deteksi kelayakan konsumsi pisang berdasarkan fitur visual menggunakan metode Jaringan Syaraf Tiruan *Multilayer Perceptron (MLP)*.

2.2 Pemrosesan Data

Penelitian ini mengikuti alur yang digunakan dalam kode proyek, di mana setiap citra pisang dibaca, diseraikan pada ukuran 224×224 piksel, kemudian dikonversi dari ruang warna *RGB* ke *HSV* untuk

memperoleh representasi warna yang lebih stabil terhadap perubahan pencahayaan. Seluruh piksel kanal *Hue*, *Saturation*, dan *Value* kemudian diratakan (*flatten*) sehingga menghasilkan 512 fitur *HSV* yang merepresentasikan distribusi warna pada permukaan pisang. Untuk mendapatkan informasi tekstur, citra juga dikonversi ke grayscale dan dihitung matriks *ko-occurrence (GLCM)* dengan beberapa parameter arah dan jarak; dari matriks tersebut diambil fitur tekstur utama seperti contrast, correlation, energy, dan homogeneity, sehingga menghasilkan total 12 fitur *GLCM*. Seluruh fitur *HSV* dan *GLCM* kemudian digabungkan menjadi vektor berdimensi 524 fitur sebagai *input* model. Label kelas kematangan diubah menjadi nilai numerik melalui label encoding, lalu seluruh data dibagi menjadi 80% data latih dan 20% data uji menggunakan stratified split agar komposisi kelas tetap seimbang. Hasil preprocessing ini memastikan bahwa setiap citra memiliki representasi fitur numerik yang konsisten dan optimal untuk proses pelatihan model klasifikasi *Multilayer Perceptron (MLP)*.

2.3 Ekstraksi Fitur

Ekstraksi fitur merupakan tahap penting untuk mengubah citra pisang menjadi representasi numerik yang dapat diolah oleh model klasifikasi. Pada penelitian ini, ekstraksi fitur dilakukan dengan menggabungkan informasi warna menggunakan ruang warna *HSV* dan informasi tekstur menggunakan metode *Grey Level Co-occurrence Matrix (GLCM)*. Citra *RGB* terlebih dahulu dikonversi ke ruang warna *HSV* karena ruang warna ini lebih stabil terhadap perubahan pencahayaan dan mampu menggambarkan perubahan warna kulit pisang secara lebih akurat. Nilai piksel dari ketiga kanal *HSV* kemudian diratakan (*flatten*), sehingga menghasilkan 512 fitur warna yang mencerminkan distribusi warna keseluruhan pada permukaan pisang.

Selain warna, karakteristik tekstur juga diekstraksi untuk menangkap pola perubahan fisik kulit pisang, seperti munculnya bintik coklat seiring meningkatnya tingkat kematangan. Citra diubah ke *grayscale*, kemudian dihitung matriks *GLCM* pada beberapa sudut dan jarak tertentu. Dari matriks tersebut diekstraksi empat fitur statistik utama, yaitu contrast, correlation, energy, dan homogeneity, sehingga menghasilkan total 12 fitur tekstur. Seluruh fitur *HSV* dan *GLCM* digabungkan menjadi vektor berdimensi 524 fitur, yang selanjutnya digunakan sebagai *input* pada model *Multilayer Perceptron (MLP)* untuk proses klasifikasi tingkat kematangan pisang.

2.4 Pelatihan Model MLP

Jaringan saraf tiruan yang disebut *MLP* adalah jenis *feedforward* jaringan saraf tiruan. Lapisan *input*, lapisan tersembunyi, dan lapisan keluaran adalah tiga lapisan node yang membentuk *MLP*, seperti yang digambarkan pada Gambar 8. Setiap node, dengan pengecualian node *input*, adalah neurondengan fungsi aktivasi non-linier. *Backpropagation* adalah teknik pembelajaran diawasi yang digunakan oleh *MLP* selama pelatihan. *MLP* dibedakan dari perceptron linier dengan banyak lapisan dan aktivasi non-linier. Ini dapat digunakan untuk membedakan data yang tidak dapat dipisahkan secara linier. Karena *input* digabungkan dengan bobot awal dalam jumlah tertimbang dan diterapkan pada fungsi aktivasi, *MLP* termasuk dalam kategori algoritma *feedforward*. Dalam *MLP*, setiap kombinasi linier diperbanyak ke lapisan berikutnya[9].

Model pada *Multilayer Perceptron (MLP)* yang terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan *output* yang saling terhubung melalui bobot dan fungsi aktivasi. Pada lapisan *input*, 143eteks neuron menerima nilai fitur dari data masukan, misalnya dalam penelitian ini sebanyak 524 fitur hasil ekstraksi *HSV* dan *GLCM*. Nilai tersebut kemudian diteruskan ke *hidden layer*, di mana 143eteks neuron 143eteksi143ka kombinasi linear berupa penjumlahan berbobot $\sum xiwi + b$, lalu melewatkannya ke activation function seperti ReLU untuk menghasilkan keluaran non-linear yang mampu menangkap pola kompleks pada data, termasuk perubahan warna dan tekstur pisang pada berbagai 143eteksi kematangan. Keluaran dari *hidden layer* selanjutnya mengalir menuju *output layer*, yang 143eteksi143kan fungsi aktivasi seperti *Softmax* untuk menghasilkan probabilitas dari 143eteks kelas, sehingga model dapat menentukan apakah citra pisang termasuk kategori mentah, setengah matang, matang, atau terlalu matang. Dengan alur tersebut, *MLP* mampu mempelajari hubungan antara fitur visual dan 143eteksi kematangan buah untuk melakukan klasifikasi secara akurat.

2.5 Evaluasi Model

Confusion matrix adalah salah satu teknik yang banyak digunakan untuk mengevaluasi performa algoritma klasifikasi, karena memberikan pandangan menyeluruh tentang pola prediksi yang dihasilkan oleh model[10]. Matriks kebingungan diuraikan sebagai alat yang tidak hanya menilai akurasi prediksi secara keseluruhan, tetapi juga membedakan kesalahan model ke dalam kategori-kategori yang lebih terperinci seperti positif benar, negatif benar, positif salah, dan negatif salah. Dengan struktur ini, peneliti dapat menghitung berbagai metrik evaluasi seperti *presisi*, *recall*, *F1-score*, dan *accuracy*, sehingga analisis performa model menjadi lebih mendetail dan objektif. Pendekatan ini sangat krusial pada penelitian klasifikasi yang melibatkan beberapa kategori, karena matriks kebingungan dapat dengan jelas menunjukkan kelas mana yang mudah diprediksi dengan benar dan kelas mana yang sering mengalami kesalahan.

1. Precision :

Menggambarkan seberapa banyak prediksi benar untuk kelas tertentu dibandingkan seluruh prediksi positif yang dibuat model.

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(1)$$

$TP = \text{True Positive}$

$FP = \text{False Positive}$

2. Recall

Menggambarkan kemampuan model menangkap seluruh data yang benar-benar termasuk dalam kelas tersebut.

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2)$$

$FN = \text{False Negative}$

3. *F1-Score*

Digunakan untuk menyeimbangkan precision dan *recall*, terutama pada dataset tidak seimbang.

$$F1 = \frac{2TP}{2TP+FP+FN} \dots\dots\dots(3)$$

4. Accuracy

Menggambarkan seberapa banyak prediksi yang benar dibandingkan seluruh data uji.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(4)$$

$TN = \text{True Negative}$

5. Macro Average

Menghitung rata-rata dari setiap metrik per kelas secara seimbang.

$$Macro\ Avg = \frac{1}{N} \sum_{i=1}^N M_i \dots\dots\dots(5)$$

$N = \text{jumlah kelas}$

$M_i = \text{nilai precision/recall/F1 kelas ke-}i$

6. Weighted Average

Menggunakan jumlah data per kelas sebagai bobot.

$$Weighted\ Avg = \frac{\sum_{i=1}^N n_i \times M_i}{\sum_{i=1}^N n_i} \dots\dots\dots(6)$$

$n_i = \text{jumlah data pada kelas ke-}i$

Metrik evaluasi digunakan untuk mengukur kualitas prediksi model klasifikasi berdasarkan hasil *confusion matrix*. Precision menunjukkan ketepatan model dalam memberikan prediksi positif, sedangkan *recall* menggambarkan kemampuan model dalam menangkap seluruh sampel yang benar pada suatu kelas. *F1-score* digunakan untuk menyeimbangkan *precision* dan *recall*, terutama ketika distribusi data tidak seimbang. Akurasi memberikan gambaran umum tentang proporsi prediksi yang benar dari seluruh data uji. Pada kasus klasifikasi

multikelas, macro average dan weighted average digunakan untuk menilai performa model secara lebih komprehensif dengan memperhitungkan variasi jumlah sampel pada tiap kelas.


3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari pengujian model untuk mendeteksi kelayakan konsumsi pisang yang dibuat dengan menggabungkan fitur warna *HSV* dan tekstur *GLCM* serta model klasifikasi *Multi Layer Perceptron (MLP)*. Proses analisis diawali dengan menunjukkan distribusi dataset untuk setiap kategori kematangan, yang berfungsi sebagai fondasi dalam menilai kualitas data serta kemungkinan adanya ketidakseimbangan antar kelas. Setelah itu, hasil dari langkah ekstraksi fitur dijelaskan untuk mengilustrasikan gambaran karakteristik visual dari masing-masing kategori pisang yang digunakan oleh model. Model *MLP* selanjutnya dievaluasi menggunakan metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *confusion matrix*, yang bertujuan untuk menilai kemampuan model dalam mengidentifikasi pisang yang masih mentah, setengah matang, matang, dan yang sudah terlalu matang. Pembahasan dalam bagian ini merinci hubungan antara kualitas data, pola fitur yang diekstraksi, dan performa model, sehingga memberikan pemahaman menyeluruh tentang efektivitas sistem dalam mendeteksi kelayakan konsumsi pisang secara otomatis.

3.1 Deskripsi Dataset

Dataset Banana Ripeness Image merupakan kumpulan citra buah pisang yang dikembangkan dan dipublikasikan oleh Telkom University melalui platform Dataverse sebagai dataset terbuka untuk keperluan penelitian. Dataset ini berisi 1.865 gambar pisang yang telah dikelompokkan ke dalam empat kelas tingkat kematangan, yaitu mentah, setengah matang, matang, dan terlalu matang. Setiap gambar memiliki resolusi seragam 224×224 piksel dengan format JPG, serta direkam menggunakan pencahayaan dan latar belakang yang relatif konsisten. Proses pelabelan kelas dilakukan secara manual oleh penyusun dataset, sehingga kualitas anotasi tergolong baik dan dapat diandalkan sebagai dasar pelatihan model klasifikasi berbasis pengolahan citra.

oleh penyusun dataset, sehingga kualitas anotasi tergolong baik dan dapat diandalkan sebagai dasar pelatihan model klasifikasi berbasis pengolahan citra.




Gambar 3. Grafik Batang Dataset

Grafik batang menunjukkan distribusi jumlah citra pisang pada setiap kelas kematangan yang digunakan dalam penelitian. Kelas setengah-matang memiliki jumlah citra terbanyak, yaitu sekitar 610 gambar, sehingga menjadi kelas dominan dalam dataset. Kelas mentah dan terlalu-matang berada pada kisaran jumlah yang hampir seimbang, masing-masing sekitar 490 dan 475 citra, sedangkan kelas matang memiliki jumlah citra paling sedikit, yaitu sekitar 295 gambar. Distribusi ini memberikan gambaran bahwa dataset tidak sepenuhnya seimbang, terutama karena kelas matang memiliki sampel yang lebih sedikit dibandingkan kelas lainnya. Kondisi ini dapat memengaruhi kinerja model *MLP*, sehingga diperlukan teknik seperti normalisasi data, penanganan imbalance, atau augmentasi agar model mampu belajar secara optimal pada semua kelas.

3.2 Preprocessing

Tahap preprocessing dilakukan untuk memastikan bahwa setiap citra pisang memiliki kualitas dan format yang seragam sebelum memasuki proses ekstraksi fitur. Pertama, seluruh citra diubah ke ukuran tetap, yaitu 224×224 piksel, agar memiliki dimensi *input* yang konsisten dan mempermudah proses komputasi pada tahap selanjutnya. Setelah itu, citra dikonversi dari ruang warna *RGB* ke ruang warna *HSV* karena *HSV* lebih stabil terhadap perubahan pencahayaan dan lebih mampu merepresentasikan perbedaan tingkat kematangan berdasarkan karakteristik warna kulit pisang. Tahap berikutnya adalah normalisasi nilai piksel agar seluruh citra memiliki rentang intensitas yang seragam sehingga mengurangi noise dan variasi yang tidak diperlukan. Untuk keperluan ekstraksi tekstur, citra selanjutnya dikonversi ke *grayscale* dan diolah menggunakan *Gray Level Co-occurrence*

Matrix (GLCM). Pada tahap ini, dilakukan kuantisasi level intensitas untuk menghasilkan matriks ko-okurensi yang kemudian menjadi dasar perhitungan fitur tekstur seperti *contrast*, *correlation*, *energy*, dan *homogeneity*. Seluruh rangkaian preprocessing ini bertujuan menghasilkan citra yang bersih, terstandarisasi, dan representatif sehingga model *MLP* dapat belajar pola warna dan tekstur secara optimal.




Gambar 4. Hasil *preprocessing*

Gambar ini menggambarkan langkah-langkah penting dalam proses pra-pemrosesan citra sebelum fitur warna dan tekstur diambil untuk tujuan klasifikasi kematangan pisang. Di bagian *RGB*, kita melihat citra asli yang diambil oleh kamera, yang masih menunjukkan variasi warna dan cahaya. Selanjutnya, pada bagian *HSV*, citra diubah ke dalam ruang warna *Hue-Saturation-Value* yang lebih konsisten terhadap variasi pencahayaan, sehingga memudahkan model untuk mengidentifikasi perbedaan tingkat kematangan berdasarkan gradasi warna kuning-hijau pada kulit pisang. Secara terpisah, bagian *Grayscale* menunjukkan citra yang telah diubah menjadi skala abu-abu, yang dijadikan dasar untuk menciptakan matriks ko-okurensi (*GLCM*). Di sisi lain, bagian *Texture* menunjukkan representasi tekstur permukaan yang diperoleh dari pengolahan *GLCM*, yang mengungkapkan pola titik dan garis halus di kulit pisang. Keempat langkah ini memastikan bahwa citra telah distandarisasi dan memiliki atribut warna serta tekstur yang siap digunakan oleh model *MLP* untuk mendeteksi kecukupan konsumsi pisang dengan akurasi yang lebih tinggi.


3.3 Ekstraksi Fitur *GLCM*

Model pada metode *GLCM* mampu mengenali deteksi kematangan pisang, 146etek hasil evaluasinya masih menunjukkan kesalahan klasifikasi pada beberapa sampel, terutama ketika citra mengalami variasi pencahayaan dan perubahan warna kulit yang tidak konsisten. Hal ini menunjukkan bahwa pendekatan berbasis tekstur saja belum 146etek stabil, sehingga penelitian ini mendefinisikan kombinasi fitur warna *HSV* dan tekstur *GLCM* serta model *MLP* untuk memperoleh performa 146eteksi kelayakan konsumsi pisang yang lebih akurat dan tahan terhadap variasi kondisi citra[10].



Gambar 5. Arah Sudut *GLCM*

Menjelaskan tentang pemilihan tetangga piksel yang dimulai dari arah kanan. Hubungan 1,0 merupakan presentasi dari hubungan 2 piksel yang bernilai 1 dan diikuti piksel yang bernilai 0 seperti yang terlihat pada gambar 6 Pasangan Piksel *GLCM* [10].



Gambar 6. Pasangan piksel matriks *GLCM*

Matriks pada Gambar 5. Pasangan Piksel *GLCM*, merupakan matriks Framework, agar matriks dapat menjadi simetris perlu diolah dengan cara menambahkan hasil tranposnya seperti yang terlihat pada Gambar 7. Pembentukan Matriks Simetris[10]

$$\begin{bmatrix} 2 & 2 & 1 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 3 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 2 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 1 & 0 & 3 & 0 \\ 0 & 0 & 1 & 1 \end{bmatrix} = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}$$

Transpos

GLCM sebelum dinormalisasi

Gambar 7. Pembentukan Matriks Simetris

Nilai-nilai *GLCM* diperlukan untuk menormalisasi elemen agar jumlahnya bernilai satu yang bertujuan menghilangkan ketergantungan pada ukuran citra seperti yang terlihat pada Gambar 8. Normalisasi MatriksCitra[10]

$$\begin{bmatrix} \frac{4}{24} & \frac{2}{24} & \frac{1}{24} & \frac{0}{24} \\ \frac{2}{24} & \frac{4}{24} & \frac{0}{24} & \frac{0}{24} \\ \frac{1}{24} & \frac{0}{24} & \frac{6}{24} & \frac{1}{24} \\ \frac{0}{24} & \frac{0}{24} & \frac{1}{24} & \frac{2}{24} \end{bmatrix}$$

Gambar 8. Normalisasi Matriks Dari Citra

Matriks pada gambar merupakan hasil normalisasi *GLCM*, yaitu proses mengubah frekuensi kemunculan pasangan nilai piksel dalam citra menjadi probabilitas. Setiap elemen pada matriks awal dibagi dengan total keseluruhan nilai (24), sehingga diperoleh nilai seperti $4/24$, $2/24$, $1/24$, dan seterusnya. Normalisasi ini menghasilkan matriks dengan rentang 0–1 yang merepresentasikan peluang kemunculan pola tekstur tertentu. Matriks probabilitas inilah yang kemudian digunakan untuk menghitung fitur-fitur tekstur *GLCM* seperti contrast, energy, homogeneity, dan correlation.

3.4 Pemodelan

Sebelum melatih model *MLP*, seluruh gambar pisang terlebih dahulu menjalani proses pengambilan fitur dengan menggunakan metode *HSV* dan *GLCM*, yang menghasilkan serangkaian data angka yang mencerminkan sifat warna dan tekstur setiap citra. Dataset fitur ini kemudian perlu dibagi menjadi dua segmen, yaitu data pelatihan dan data pengujian, agar performa model dapat dinilai secara objektif. Pembagian ini dilakukan dengan

metode train-test split yang menggunakan rasio 80% untuk data pelatihan dan 20% untuk data pengujian. Hasil dari pembagian dataset ini dapat dilihat pada gambar berikut.

```
X = np.array(X, dtype="float32")
y = np.array(y)

x_train, x_test, y_train, y_test = train_test_split(
    X, y,
    test_size=0.2,
    random_state=0,
    shuffle=True
)

print("Banyaknya X-training :", len(x_train))
print("Banyaknya X-test :", len(x_test))
print("Banyaknya Y-training :", len(y_train))
print("Banyaknya Y-test :", len(y_test))
```

0.0s


Banyaknya X-training : 1192
Banyaknya X-test : 298
Banyaknya Y-training : 1192
Banyaknya Y-test : 298

Gambar 9. Pembagian Dataset ke Dalam Data Latih dan Data Uji

Hasil pembagian dataset menunjukkan bahwa total 1.490 sampel fitur berhasil dikumpulkan dari seluruh citra pisang yang telah melalui proses ekstraksi *HSV* dan *GLCM*. Dari jumlah tersebut, algoritma *train_test_split* membagi dataset menjadi 80% data latih dan 20% data uji, sesuai parameter *test_size=0.2*. Pembagian ini menghasilkan 1.192 data latih dan 298 data uji untuk masing-masing fitur (X) maupun label (y). Komposisi ini memastikan bahwa model *MLP* akan memperoleh jumlah data yang cukup besar untuk proses pembelajaran, sementara subset data uji tetap representatif untuk mengevaluasi kemampuan model dalam melakukan prediksi pada data yang belum pernah dilihat sebelumnya. Pembagian yang seimbang ini penting untuk menjaga kualitas pelatihan sekaligus menghindari bias evaluasi.

3.5 Hasil Evaluasi

Evaluasi ini diperlukan untuk melihat sejauh mana model mampu membedakan tingkat kelayakan konsumsi buah pisang berdasarkan variasi warna dan tekstur pada masing-masing kelas. Salah satu metode evaluasi yang digunakan adalah *confusion matrix*, yang memberikan gambaran detail mengenai jumlah prediksi benar dan salah pada setiap kelas. Melalui *confusion matrix*, dapat terlihat pola kesalahan klasifikasi, kelas mana yang paling mudah dikenali model, serta kelas mana yang sering tertukar akibat kemiripan karakteristik visual. Gambar berikut menampilkan *confusion matrix* hasil prediksi model *MLP* pada data uji.



Gambar 10. Hasil *Confusion Matrix* Model *MLP*

Confusion matrix yang terlihat pada gambar menunjukkan bahwa seluruh nilai prediksi dari model terletak pada angka nol untuk setiap kombinasi dari kelas, baik yang terdapat pada baris (label sebenarnya) maupun kolom (label hasil prediksi). Ini menunjukkan bahwa model *MLP* tidak mampu menghasilkan prediksi kelas yang tepat atau tidak mampu mengeluarkan label yang sesuai, sehingga tidak ada data uji yang berhasil dikategorikan ke dalam salah satu dari empat kelas kematangan pisang. Situasi ini umumnya terjadi ketika model tidak dilatih dengan baik, fitur yang digunakan tidak cocok, label tidak dapat terdeteksi, atau jika hasil prediksi adalah nilai kosong atau konstan yang membuat matriks kebingungan tidak bisa mengidentifikasi jumlah kasus yang benar maupun yang salah. Dengan kata lain, matriks kebingungan ini menunjukkan bahwa prediksi dari model tidak berlangsung dengan baik dan perlu ada peninjauan

kembali pada proses pelatihan, yang mencakup validasi fitur, format *input*, pengkodean label, serta proses pemodelan pada *MLP*.

Tabel 1. Hasil Evaluasi Kinerja Model *MLP* Berdasarkan *Precision*, *Recall*, *F1-Score*, dan *Accuracy*

Kelas	Precision	Recall	F1-Score
Mentah	0.988095	1.000000	0.994012
Setengah-matang	1.000000	0.989247	0.994595
Matang	1.000000	0.964912	0.982143
Terlalu-matang	0.970149	1.000000	0.984848
Rata-rata Makro	0.989561	0.988540	0.988899
Rata-rata Tertimbang	0.990173	0.989933	0.989925
Akurasi Total	0.9899328859060402		

Tabel evaluasi tersebut menunjukkan bahwa model *MLP* memiliki performa yang sangat baik dalam mengklasifikasikan tingkat kematangan pisang, dengan nilai *precision*, *recall*, dan *F1-score* yang berada pada kisaran 0.97 hingga 1.00 pada semua kelas. Keempat kelas, yaitu mentah, setengah-matang, matang, dan terlalu-matang, mampu dikenali model dengan konsisten tanpa kesalahan signifikan. Nilai rata-rata makro dan tertimbang yang mendekati 0.99 serta akurasi total sebesar 98.99% menegaskan bahwa kombinasi fitur *HSV* dan *GLCM* mampu memberikan representasi citra yang efektif sehingga model *MLP* dapat menghasilkan prediksi yang sangat akurat dan stabil.

4. SIMPULAN

Penelitian ini menunjukkan bahwa kombinasi fitur warna *HSV* dan tekstur *GLCM* mampu memberikan representasi citra yang efektif untuk mendeteksi tingkat kematangan pisang menggunakan model *MLP*. Hasil evaluasi yang sangat tinggi pada semua metrik menegaskan bahwa pendekatan ini stabil dalam mengenali perbedaan visual antar kelas. Keunggulan utama sistem terletak pada arsitektur model yang sederhana namun efisien, sehingga mudah diterapkan pada perangkat berspesifikasi rendah maupun aplikasi pemantauan kualitas buah secara praktis. Meski demikian, akurasi model masih dipengaruhi oleh keseragaman pencahayaan dan latar belakang citra pada dataset, sehingga performanya dapat menurun dalam kondisi lingkungan yang lebih bervariasi. Ke depan, penelitian ini dapat dikembangkan melalui peningkatan keragaman data, penggunaan metode augmentasi yang lebih luas, serta eksplorasi model berbasis *deep learning* atau integrasi ke dalam aplikasi *real-time* untuk mendukung proses sortir dan penilaian kualitas buah secara otomatis.

5. SARAN

Penelitian selanjutnya disarankan untuk memperluas variasi dataset dengan menambah citra pisang dari berbagai kondisi pencahayaan, latar belakang, dan jenis kamera agar model menjadi lebih robust terhadap perubahan lingkungan. Teknik augmentasi data yang lebih beragam juga perlu diterapkan untuk mengurangi ketergantungan model pada pola visual tertentu dan mengatasi potensi *overfitting*. Selain itu, metode ekstraksi fitur dapat ditingkatkan dengan memanfaatkan pendekatan berbasis *deep learning* seperti *CNN* agar representasi fitur menjadi lebih adaptif dan mampu menangkap detail tekstur yang lebih kompleks. Pengujian terhadap arsitektur *MLP* yang berbeda atau penggunaan metode optimisasi lanjutan juga dapat dilakukan untuk menemukan konfigurasi model yang lebih optimal. Terakhir, penelitian lanjutan perlu mengintegrasikan proses validasi silang (*cross-validation*) agar evaluasi performa model lebih komprehensif dan tidak bergantung pada satu kali pembagian dataset.

DAFTAR PUSTAKA

- [1] N. L. Firda Ekayanti, F. Megawati, and N. L. K. A. Anita Dewi, “PEMANFAATAN TANAMAN PISANG (*Musa Paradisiaca* L.) SEBAGAI SEDIAAN KOSMETIK,” *Usadha*, vol. 2, no. 2, pp. 19–24, Apr. 2023, doi: 10.36733/usadha.v2i2.6217.
- [2] R. T. Wulandari, N. Widyastuti, and M. Ardiaria, “PERBEDAAN PEMBERIAN PISANG RAJA DAN PISANG AMBON TERHADAP VO₂max PADA REMAJA DI SEKOLAH SEPAK BOLA,” *Journal of Nutrition College*, vol. 7, no. 1, 2018, [Online]. Available: <http://ejournal3.undip.ac.id/index.php/jnc/>
- [3] M. P. S. Staf *et al.*, “Potensi Pengembangan Tanaman Pisang : Tinjauan Syarat Tumbuh dan Teknik Budidaya Pisang Dengan Metode Bit,” *Jurnal Ilmiah Agrosaint*, vol. 12, no. 2, 2021.
- [4] “PISANG INDONESIA.”
- [5] K. Tingkat, K. Buah, P. Berdasarkan, P. M. Algoritma, D. M. Puteri, and H. Setiawan, “Algorithmic Model Approach”, doi: 10.30595/jrre.v7i2.26293.
- [6] N. W. Wulansari and M. Muslih, “Implementasi Metode Convolutional Neural Network Untuk Deteksi Kematangan Buah Pisang Menggunakan Inception V3,” *JOINS (Journal of Information System)*, vol. 8, no. 2, pp. 147–155, Nov. 2023, doi: 10.33633/joins.v8i2.9074.
- [7] M. S. Y. Radiena, B. Riset, D. Standardisasi, I. Ambon, and J. Kebun Cengkeh, “UMUR OPTIMUM PANEN PISANG KEPOK (*Musa paradisiaca*, L) TERHADAP MUTU TEPUNG PISANG OPTIMUM MATURITY OF KEPOK BANANA’S (*Musa paradisiaca*, L) HARVEST AGAINST QUALITY OF BANANA FLOUR.”
- [8] R. Hayati and D. Irhamni, “PENGARUH TINGKAT KEMATANGAN DAN LAMA PENYIMPANAN TERHADAP KUALITAS PISANG MAS (*Musa acuminata* Colla) Effect of Maturity Level and Storage Duration on Quality Banana Mas (*Musa acuminata* Colla),” 2023.
- [9] “Lisensi Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0”, doi: 10.52158/jacost.484.
- [10] M. Tri Wahyudi and S. Lestari, “Analisis Kematangan Buah Pisang dengan Metode Gray Level Co-Occurrence Matrix (GLCM) Banana Fruit Ripeness Analysis Using the Gray Level Co-Occurrence Matrix (GLCM) Method,” vol. 1, no. 2, 2022, doi: 10.22437/multiproximity.v1i2.18630.