

## Classification of Watermelon Flavor Using Artificial Neural Network with Color, Texture, and Shape Features

Muh Faqih S Musgamy<sup>1</sup>, Muhammad Risaldi<sup>2</sup>, Ayu Safitri<sup>3</sup>, Andi Baso Kaswar<sup>\*4</sup>, Muhammad Fajar B<sup>5</sup>, Jumadi M Parenreng<sup>6</sup>

<sup>1,2,3,4,5,6</sup>Teknik Komputer, Fakultas Teknik, Universitas Negeri Makassar, Indonesia

Email: <sup>4</sup>a.baso.kaswar@unm.ac.id

Received : Nov 17, 2025; Revised : Feb 2, 2026; Accepted : Feb 9, 2026; Published : Jun 15, 2026

### Abstract

Watermelon (*Citrullus vulgaris* Schard) is a widely produced fruit due to its high nutritional value and health benefits. However, consumers often experience difficulty in distinguishing sweet and bland watermelons because quality assessment is generally conducted manually and subjectively. To address this issue, this study proposes a watermelon flavor classification system based on visual features, including color, texture, and shape, using an Artificial Neural Network approach with digital image processing. The dataset used in this study consists of 214 images collected from 55 watermelon samples, categorized into sweet and bland classes. The proposed method involves several stages, namely image acquisition, preprocessing, grayscale conversion, segmentation, morphological operations, feature extraction, and classification using a feedforward backpropagation learning algorithm. Various combinations of visual features were evaluated to determine the most effective configuration. Experimental results show that the proposed system achieves an accuracy of 93.67% on training data and 92.85% on testing data, with an average computation time of 0.319 seconds per image. The findings indicate that the integration of Hue Saturation Value color features, texture features derived from the Gray-Level Co-occurrence Matrix, and shape features significantly enhances the accuracy of watermelon flavor classification. This study contributes to the development of an objective, efficient, and non-destructive fruit quality assessment system and demonstrates potential applicability to other types of fruits using a similar approach.

**Keywords :** *Artificial Neural Network, Digital Image Processing, Watermelon Flavor Classification.*

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



## 1. PENDAHULUAN

Semangka (*Citrullus vulgaris* Schard) merupakan salah satu tanaman hortikultura penting di daerah tropis dan subtropis karena memberikan berbagai manfaat. Buah ini memiliki bentuk dan ukuran yang beragam, seperti bulat, oval, persegi, atau bentuk tidak beraturan lainnya [1]. Pada kondisi matang, semangka umumnya ditandai dengan bobot yang lebih berat, perubahan warna kulit dari kehijauan atau putih menjadi hijau cerah, serta permukaan kulit yang halus dan tampak sedikit kusam, sehingga dapat membantu konsumen mengenali kualitas buah [2]. Selain sebagai indikator kematangan, perubahan karakteristik visual pada kulit semangka juga berkaitan dengan proses fisiologis buah selama pertumbuhan, seperti akumulasi pigmen dan perkembangan jaringan sel yang berhubungan dengan kualitas internal buah [3].

Kualitas rasa merupakan aspek penting dalam penilaian semangka. Meskipun sebagian besar semangka memiliki rasa manis, sebagian lainnya dapat terasa hambar. Dalam konteks penjualan, semangka yang manis memiliki nilai jual lebih tinggi karena dianggap memiliki kualitas yang lebih baik. Dengan demikian, kualitas semangka dipengaruhi oleh beberapa faktor, seperti jenis, ukuran, dan tingkat kematangan buah [4]. Secara umum, buah semangka yang siap dipanen atau telah matang menunjukkan beberapa ciri fisik yang dapat diamati secara visual, seperti warna dan tekstur kulit yang

tampak lebih bersih, jelas, dan mengkilap, serta pola garis kulit yang lebih tegas [5]. Selain itu, sulur kecil di dekat tangkai buah biasanya mengering dan berubah warna menjadi coklat tua, sedangkan bagian dasar buah yang bersentuhan dengan tanah mengalami perubahan warna dari putih menjadi kuning tua. Ciri-ciri fisik tersebut sering digunakan secara empiris oleh petani dan pedagang sebagai indikator kematangan dan kualitas buah [3][6]. Selain rasa, nilai gizi juga menjadi salah satu keunggulan semangka. Buah ini memiliki kandungan nutrisi yang tinggi dan bermanfaat bagi kesehatan tubuh manusia [7][8]. Dalam 100 gram semangka, terdapat sekitar 28 kalori, 0,5 gram protein, 6,9 gram karbohidrat, 6 mg vitamin C, 590 µg vitamin A, 0,3 mg abu, 7 mg kalsium, 0,2 mg zat besi, dan 12 mg fosfor [9].

Semangka juga berkontribusi secara signifikan terhadap produksi pertanian di Indonesia. Berdasarkan data statistik, produksi semangka pada tahun 2021 mencapai 414.242 ton. Namun, pada tahun 2022 jumlah tersebut menurun menjadi 367.816 ton, sebelum kembali meningkat menjadi 408.115 ton pada tahun 2023 [10]. Data ini menunjukkan bahwa semangka merupakan salah satu komoditas pertanian yang banyak diproduksi, sehingga kualitasnya perlu diperhatikan. Selama ini, penilaian kualitas semangka masih dilakukan secara manual oleh petani dan pedagang berdasarkan pengalaman, bentuk, serta warna kulit buah. Pendekatan tersebut bersifat subjektif dan tidak selalu mencerminkan kondisi internal buah, khususnya tingkat kemanisan, sehingga konsumen sering mengeluhkan semangka yang kurang manis atau hambar. Oleh karena itu, diperlukan metode yang lebih andal dan objektif untuk menilai kualitas semangka sehingga konsumen dapat memilih buah yang sesuai dengan harapan mereka [11].

Penelitian sebelumnya telah berupaya memecahkan permasalahan terkait penentuan rasa buah menggunakan pendekatan pemrosesan citra dan pembelajaran mesin. Salah satunya adalah penelitian berjudul *Lima Fitur Matriks Co-Occurrence Tingkat Abu-abu untuk Deteksi Rasa Manis Buah Semangka Tanpa Biji dengan Klasifikasi Mesin Vektor Pendukung Berbasis Raspberry Pi*, yang menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM) dan *Support Vector Machine* (SVM). Hasil penelitian tersebut menunjukkan bahwa metode yang digunakan cukup efektif dengan tingkat akurasi mencapai 80%, namun masih terbatas pada penggunaan fitur tekstur dan sudut pengambilan citra tertentu [12]. Penelitian berikutnya dilakukan oleh Nurfitri dan Mushawwir yang memanfaatkan *Artificial Neural Network* (ANN) untuk mengklasifikasikan kandungan gula pada buah berbasis citra digital. Pada buah pisang dan pepaya, metode ini menghasilkan akurasi tinggi, namun membutuhkan waktu komputasi yang relatif lama dan sangat bergantung pada kualitas citra yang digunakan [13][14]. Penelitian lain menerapkan pemrosesan citra digital dan pembelajaran mesin pada buah semangka dengan tujuan yang berbeda-beda. Salah satu penelitian menggabungkan fitur tekstur *Gray Level Co-Occurrence Matrix* dengan algoritma *Backpropagation Neural Network* untuk mendeteksi tingkat kemanisan semangka dan melaporkan akurasi pengujian sebesar 85,7%, namun masih terbatas pada penggunaan fitur tekstur saja serta memiliki waktu komputasi yang relatif tinggi [15]. Selanjutnya, penelitian yang menggunakan metode *K-Nearest Neighbor* untuk klasifikasi jenis semangka berdasarkan fitur visual warna dan bentuk, dengan akurasi pengujian sekitar 80%, tetapi belum menyentuh aspek kualitas internal seperti rasa [16].

Selain itu, penelitian oleh Zheng Liu menggunakan *Deep Neural Networks* (DNN) untuk mengevaluasi rasa anggur meja dan mencapai akurasi sebesar 94,8%. Meskipun memberikan hasil yang baik, pendekatan DNN memerlukan dataset berukuran besar serta sumber daya komputasi yang tinggi, sehingga kurang efisien untuk implementasi praktis dengan data terbatas [17]. Penelitian lain menggunakan algoritma *Naive Bayes* dan *Support Vector Machine* untuk mengklasifikasikan tingkat kemanisan apel dan alpukat berdasarkan fitur warna, dengan hasil akurasi yang cukup tinggi, namun masih mengandalkan satu jenis fitur visual dan diterapkan pada jenis buah tertentu [1][18]. Studi oleh Chairati dan Jessica juga menunjukkan bahwa pendekatan berbasis pemrosesan citra digital dan Jaringan

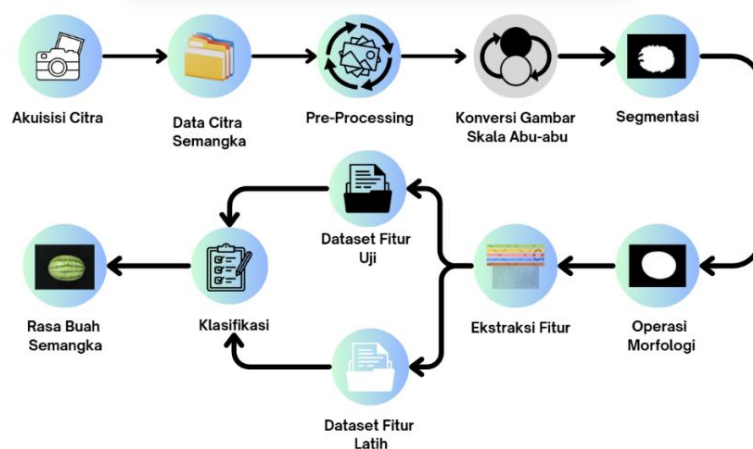
Saraf Tiruan efektif dalam klasifikasi rasa buah, seperti salak dan jeruk siam, tetapi masih terbatas pada kombinasi fitur tertentu dan kondisi pengambilan citra yang spesifik [19][20].

Berdasarkan tinjauan terhadap penelitian-penelitian terdahulu, dapat disimpulkan bahwa sebagian besar pendekatan yang ada masih memanfaatkan fitur visual tunggal atau terbatas, seperti warna atau tekstur saja, serta belum secara khusus difokuskan pada klasifikasi rasa semangka yang memiliki karakteristik visual kulit yang kompleks. Selain itu, beberapa penelitian menggunakan metode klasifikasi konvensional seperti *Support Vector Machine*, yang kinerjanya sangat bergantung pada pemilihan kernel dan parameter, sehingga kurang fleksibel dalam memodelkan hubungan *non-linear* yang kompleks antara fitur visual dan rasa buah. Di sisi lain, pendekatan berbasis *Deep Neural Network* mampu memberikan akurasi tinggi, namun umumnya memerlukan dataset berukuran besar dan sumber daya komputasi yang tinggi, sehingga kurang efisien untuk aplikasi praktis dengan data terbatas [21][22]. Kondisi tersebut menunjukkan bahwa masih terdapat celah penelitian dalam pengembangan metode klasifikasi rasa semangka yang mampu mengakomodasi kompleksitas ciri visual buah sekaligus tetap efisien secara komputasi.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sistem klasifikasi rasa semangka, bukan tingkat kematangan, menggunakan *Artificial Neural Network* berbasis pemrosesan citra digital dengan kombinasi fitur warna, tekstur, dan bentuk. Dalam konteks ini, rasa manis atau hambar dipahami sebagai persepsi sensorik yang berkaitan erat dengan kandungan gula terlarut dalam buah, yang meskipun tidak diukur secara langsung melalui citra, dapat direpresentasikan secara tidak langsung melalui ciri visual eksternal [23]. Proses fisiologis selama pertumbuhan buah, seperti fotosintesis dan distribusi nutrisi, memengaruhi akumulasi gula sekaligus berdampak pada warna kulit, pola garis, tekstur permukaan, dan bentuk buah, sehingga ciri-ciri tersebut dapat digunakan sebagai indikator visual untuk klasifikasi rasa secara non-destruktif [24] [25]. Dengan menggabungkan ketiga jenis fitur visual tersebut dan memanfaatkan kemampuan *Artificial Neural Network* dalam memodelkan hubungan *non-linear*, penelitian ini bertujuan merancang dan mengimplementasikan sistem yang mampu membedakan semangka manis dan hambar secara akurat, efisien, dan aplikatif.

## 2. METODOLOGI PENELITIAN

Penelitian ini mengusulkan pendekatan yang terdiri dari sejumlah langkah yang harus diselesaikan, sebagaimana yang ditunjukkan pada Gambar 1.



Gambar 1. Tahapan metode yang diusulkan

### 2.1. Akuisisi Citra

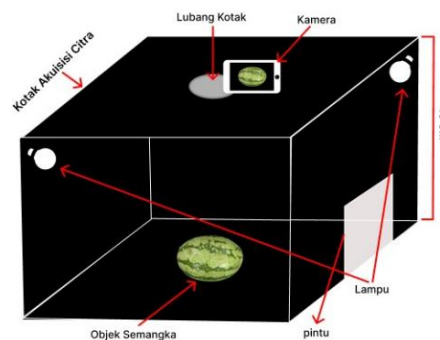
Pada tahap ini, 55 buah semangka digunakan sebagai sampel penelitian. Pengumpulan dataset gambar ditunjukkan pada Gambar 2.



Gambar 2. Pengumpulan Citra Buah Semangka

Pada Gambar 2, sebanyak 55 buah semangka digunakan, menghasilkan dataset sebanyak 214 citra. Dataset ini terdiri dari 107 citra semangka dengan rasa manis dan 107 citra semangka dengan rasa hambar. Penentuan label rasa semangka pada penelitian ini dilakukan melalui uji rasa langsung (*sensory evaluation*) setelah proses pengambilan citra selesai. Setiap buah semangka dipotong dan dicicipi oleh lima panelis, kemudian masing-masing panelis memberikan penilaian terhadap rasa semangka ke dalam dua kategori, yaitu manis atau hambar. Label akhir untuk setiap buah semangka ditentukan berdasarkan suara terbanyak (*majority voting*) dari kelima panelis tersebut.

Pendekatan ini dipilih karena uji rasa langsung masih dianggap sebagai salah satu metode yang paling umum dan representatif dalam menilai persepsi rasa manis pada buah, terutama dalam studi pangan dan hortikultura. Rasa manis pada semangka terutama dipengaruhi oleh kandungan gula terlarut, yang secara sensorik dapat dikenali oleh manusia [8]. Proses pengambilan dataset dilakukan seperti pada Gambar 3.



Gambar 3. Proses Akuisisi Citra

Gambar 3 menunjukkan proses akuisisi citra menggunakan kamera *Android Xiaomi 13T* yang diatur secara manual dengan ISO 353, *f-stop*  $f/1.9$ , waktu pencahayaan  $1/100$  detik, dan panjang fokus 7 mm, tanpa menggunakan lampu kilat. Citra yang dihasilkan memiliki resolusi  $4069 \times 3072$  piksel. Proses akuisisi citra dilakukan menggunakan latar belakang berwarna hitam yang diletakkan di dalam sebuah kotak bercahaya, di mana kamera diposisikan pada bagian atas kotak melalui sebuah lubang untuk menangkap citra objek di dalamnya. Jarak vertical antara kamera dan objek dan objek ditetapkan sebesar 40 cm. Pengaturan ini dirancang untuk menjaga konsistensi kualitas citra sehingga hasil yang diperoleh stabil serta minim pengaruh noise dan variasi intensitas pencahayaan.

## 2.2. Preprocessing

Pada tahap ini, citra hasil akuisisi diproses secara visual guna meningkatkan kualitas citra agar tahapan selanjutnya dapat dilakukan secara lebih optimal. Citra kemudian dipisahkan ke dalam tiga saluran warna RGB, yaitu merah, hijau, biru. Dalam penelitian ini, saluran hijau dipilih untuk dianalisis lebih lanjut karena warna hijau pada permukaan kulit semangka memiliki tingkat dominasi yang lebih

tinggi. Saluran tersebut digunakan hingga tahap akhir, yaitu klasifikasi. Pada tahap *preprocessing*, nilai intensitas saluran hijau dikurangi sebesar 15 untuk menghasilkan tampilan yang lebih gelap, kemudian dikalikan delapan untuk meningkatkan kontras pada area berwarna hijau tua. Selanjutnya, citra asli dikonversi menjadi citra skala abu-abu. Skala abu-abu merupakan proses konversi citra di mana nilai intensitas piksel ditentukan berdasarkan tingkat keabu-abuan. Dalam penelitian ini, citra skala abu-abu dari saluran hijau digunakan sebagai nilai ambang awal yang akan diterapkan pada tahap segmentasi berikutnya. [26].

### 2.3. Segmentasi

Segmentasi citra merupakan tahapan krusial dalam pengolahan citra yang bertujuan untuk memisahkan objek utama dari latar belakang, sehingga objek tersebut dapat dianalisis secara lebih efektif dan akurat [27][28]. Dalam penelitian ini, metode segmentasi berbasis ambang batas *Otsu* diterapkan untuk mengelompokkan citra ke dalam dua kelas, yaitu objek dan latar belakang. Metode *Otsu* dipilih karena mampu mendeteksi perbedaan intensitas warna antara objek dan latar belakang, kemudian menentukan nilai ambang optimal yang digunakan sebagai pemisah kedua area tersebut [29]. Nilai ambang yang dihasilkan dari histogram saluran hijau selanjutnya digunakan untuk mengonversi citra menjadi citra biner dengan nilai 0 untuk latar belakang dan 1 untuk objek.

Dalam penelitian ini, berdasarkan hasil pengamatan histogram pada saluran hijau dari tahap *preprocessing*, diperoleh citra biner dengan bagian putih bernilai 1 sebagai objek dan bagian hitam bernilai 0 sebagai latar belakang. Proses konversi citra RGB menjadi citra biner ini memungkinkan pemisahan objek dan latar belakang, namun sering kali menghasilkan *noise* pada citra. Oleh sebab itu, operasi morfologi diterapkan sebagai tahapan lanjutan guna menghasilkan bentuk objek yang lebih bersih serta mendekati kondisi yang diharapkan.

### 2.4. Operasi Morfologi

Proses segmentasi pada tahap sebelumnya belum mampu menghasilkan pemisahan objek secara optimal. Oleh karena itu, pada tahap ini diterapkan operasi morfologi untuk mengurangi *noise* dan memperbaiki kualitas citra hasil segmentasi. Operasi morfologi merupakan metode yang digunakan untuk memodifikasi struktur citra serta menghilangkan *noise*. Beberapa teknik umum dalam operasi morfologi meliputi *dilation*, *erosion*, *opening*, *closing*, *hole filling*, dan *bwareaopen* [30].

*Dilation* adalah teknik yang digunakan untuk memperbesar ukuran objek dengan mengisi celah-celah kecil pada area objek. Sebaliknya, *erosion* berfungsi mengurangi piksel pada tepi objek untuk menghilangkan bagian-bagian kecil yang tidak relevan dalam analisis citra [31]. *Opening* merupakan operasi yang dilakukan dengan menerapkan *erosion* terlebih dahulu, kemudian diikuti oleh *dilation*. Sementara itu, *closing* adalah kebalikan dari *opening*, yaitu *dilation* yang diikuti oleh *erosion*. Operasi *hole filling* digunakan untuk mengisi lubang di dalam area objek, sedangkan *bwareaopen* berfungsi menghapus objek kecil tertentu dalam citra yang dianggap sebagai *noise* [30].

Dalam operasi morfologi, *structuring element (strel)* merupakan komponen yang digunakan untuk menentukan bentuk dan ukuran area yang diproses, dan memiliki berbagai bentuk, termasuk sepuluh jenis bentuk dasar yang umum digunakan [32]. Pada penelitian ini, langkah pertama adalah membuat *strel* berbentuk *disk* dengan ukuran 100 piksel yang akan digunakan dalam proses morfologi selanjutnya. Teknik *bwareaopen* kemudian diterapkan pada citra hasil segmentasi untuk menghilangkan *noise* berukuran kecil. Selanjutnya, dilakukan operasi *hole filling* untuk mengisi bagian berlubang yang masih terdapat di dalam objek. Selanjutnya, teknik *erosion* digunakan untuk mengurangi piksel pada bagian tepi objek sesuai dengan *strel* yang digunakan. Operasi *bwareaopen* diterapkan kembali untuk memastikan bahwa *noise* kecil yang tersisa dapat dihilangkan sepenuhnya. Tahap berikutnya adalah *dilation*, yang dilakukan untuk menambah kembali piksel pada area tepi objek dan mengembalikan

ukuran objek yang berkurang akibat proses *erosion*. Rangkaian langkah tersebut menghasilkan objek yang lebih bersih dan bebas dari *noise*.

## 2.5. Ekstraksi Fitur

Ekstraksi fitur merupakan tahap penting dalam pemrosesan citra digital yang bertujuan memperoleh atribut dari setiap citra setelah melalui proses segmentasi dan operasi morfologi. Atribut tersebut biasanya meliputi warna, tekstur, dan bentuk. Pemilihan fitur harus dilakukan secara tepat karena berpengaruh langsung terhadap keberhasilan proses klasifikasi [30][22]. Pada penelitian ini, fitur yang digunakan sebagai masukan pada tahap klasifikasi meliputi warna, tekstur, dan bentuk. Pada ekstraksi fitur warna digunakan model *Hue Saturation Value* (HSV), yaitu suatu model representasi warna yang memisahkan informasi warna ke dalam tiga komponen utama, yaitu *hue* (rona), *saturation* (kejenuhan), dan *value* (kecerahan) Model ini memungkinkan pemisahan informasi warna secara lebih efektif [33]. Konversi warna RGB ke HSV dapat dilihat pada persamaan (1)-(6).

$$C_{max} = \max(R, G, B) \quad (1)$$

$$C_{min} = \min(R, G, B) \quad (2)$$

$$\Delta = C_{max} - C_{min} \quad (3)$$

Nilai Hue (H) dihitung sebagai:

$$H = \begin{cases} 0, & \Delta = 0 \\ 60^\circ \times \left(\frac{G-B}{\Delta} \bmod 6\right), & C_{max}=R \\ 60^\circ \times \left(\frac{B-R}{\Delta} + 2\right), & C_{max}=G \\ 60^\circ \times \left(\frac{R-G}{\Delta} + 4\right), & C_{max}=B \end{cases} \quad (4)$$

Nilai saturation (S) dihitung sebagai:

$$S = \begin{cases} 0, & C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & C_{max} \neq 0 \end{cases} \quad (5)$$

Nilai Value (V) didefinisikan sebagai:

$$V = C_{max} \quad (6)$$

Pada penelitian ini, ekstraksi fitur tekstur dilakukan menggunakan metode Gray-Level Co-occurrence Matrix (GLCM) yang dihitung dari citra hasil pemotongan objek semangka. Perhitungan GLCM dilakukan menggunakan jarak piksel (distance) sebesar 1 piksel dengan orientasi sudut 0° (horizontal), sesuai dengan parameter default pada fungsi *graycomatrix* di MATLAB. Fitur tekstur yang diekstraksi dari matriks GLCM meliputi kontras, korelasi, energi, dan homogenitas, yang dihitung menggunakan fungsi *graycoprops* [34][21]. Penggunaan satu arah orientasi dipilih untuk merepresentasikan hubungan spasial lokal antar-piksel pada permukaan kulit semangka, dengan asumsi bahwa pola tekstur kulit semangka relatif homogen dan tidak bergantung pada orientasi tertentu. Pendekatan ini juga bertujuan menjaga efisiensi komputasi tanpa mengurangi kemampuan representasi tekstur secara signifikan. Perhitungan fitur dapat dilihat pada persamaan (7)-(8).

$$Contrast = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i-j)^2 P(i,j) \quad (7)$$

$$Correlation = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (8)$$

$$Energy = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i,j)^2 \quad (9)$$

$$Homogeneity = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P(i,j)}{1+|i-j|} \quad (10)$$

Selain itu, fitur bentuk yang digunakan meliputi nilai luas, eksentrisitas, metrik, dan keliling. Nilai luas digunakan untuk menghitung jumlah piksel yang membentuk objek pada citra semangka, yang mencerminkan ukuran objek dalam satuan piksel. Eksentrisitas digunakan untuk mengukur tingkat kedekatan bentuk objek terhadap lingkaran sempurna, di mana nilai yang semakin mendekati nol menunjukkan bentuk objek yang semakin bulat, sedangkan nilai yang lebih besar mengindikasikan bentuk yang cenderung oval atau memanjang. Metrik merupakan parameter yang digunakan untuk menilai hubungan antara keliling dan luas objek, sehingga dapat memberikan informasi mengenai tingkat kompleksitas bentuk. Sementara itu, nilai keliling dihitung untuk menentukan panjang batas luar objek, yang berguna dalam mengidentifikasi pola serta karakteristik kontur kulit semangka. Perhitungan luas, keliling, metrik, dan eksentrisitas dilakukan menggunakan persamaan (11)-(14).

$$Luas Area = \sum_{x,y} I(x,y) \quad (11)$$

$$Keliling Perimeter = \sum boundary pixels \quad (12)$$

$$Metric = \frac{4\pi}{P^2} \quad (13)$$

$$Eksentrisitas = \frac{c}{a} \quad (14)$$


## 2.6. Klasifikasi

Dalam proses klasifikasi semangka, langkah pertama adalah membagi kedua data citra yaitu 75% data pelatihan dan 25% data uji dari total citra. Pembagian dataset ditunjukkan pada Tabel 1.

Tabel 1. Pembagian Dataset

Kelas	Dataset		Total
	Latih	Uji	
<b>Manis</b>	79	28	107
<b>Hambar</b>	79	28	107
<b>Total</b>	158	56	214

Pembagian dataset dalam Tabel 1 akan digunakan sebagai data untuk model klasifikasi Jaringan Saraf Buatan yang dibangun dengan arsitektur yang ditunjukkan pada Gambar 4.



Gambar 4. Arsitektur Artificial Neural Network

Pada Gambar 4, metode klasifikasi yang digunakan adalah *Artificial Neural Network (ANN)* dengan algoritma *Feedforward Backpropagation*. Seperti terlihat pada Citra 4, arsitektur ANN terdiri atas 11 *neuron* pada lapisan input dan dua lapisan tersembunyi, yaitu lapisan pertama dengan 10 *neuron* dan lapisan kedua dengan 5 *neuron*, keduanya menggunakan fungsi aktivasi *log-sigmoid*. Lapisan keluaran memiliki satu *neuron*. Dalam model ANN yang diterapkan, jumlah *epoch* yang digunakan adalah 1000 dengan target kesalahan sebesar  $1 \times 10^{-6}$ . Proses pelatihan dilakukan dengan menggunakan fungsi *train* yang mengimplementasikan algoritma *Levenberg-Marquardt* untuk mengoptimalkan penyesuaian bobot dan bias [35]. Metode ini bertujuan meminimalkan kesalahan dan menemukan kombinasi bobot terbaik untuk menghasilkan prediksi yang akurat. Aturan pembaruan bobot ditunjukkan pada persamaan (15).


$$w_{ij}(t + 1) = w_{ij}(t) + \eta \cdot \delta_i \cdot x_i \quad (15)$$

### 3. HASIL DAN PEMBAHASAN

Dalam penelitian ini dikumpulkan sebanyak 214 citra semangka yang dibagi ke dalam dua kelas, yaitu manis dan hambar. Himpunan data ini terdiri atas dua kategori citra pelatihan dan citra pengujian. Citra pelatihan mencakup 75% dari total data, yakni 158 citra, dengan masing-masing kelas memiliki 79 citra. Sementara itu, citra pengujian mencakup 25% dari total data, yaitu 56 citra, dengan masing-masing kelas berjumlah 28 citra. Hasil akuisisi citra berdasarkan tiap kelas ditunjukkan pada Gambar 5.




Gambar 5. Contoh Citra Asli dari (a) Kelas Manis dan (b) Hambar



Gambar 6. Contoh Citra Skala Abu-abu dari (a) Kelas Manis dan (b) Hambar

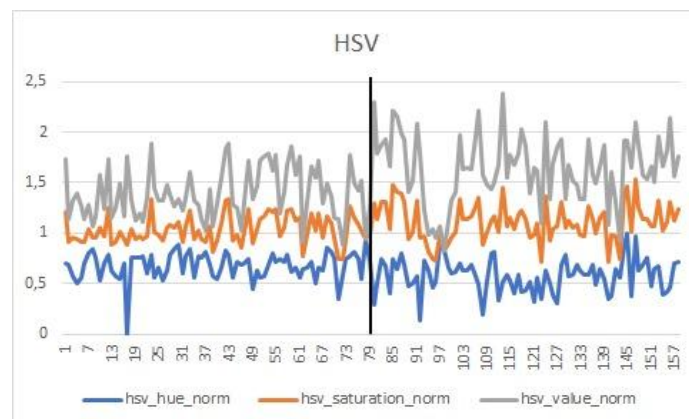
Gambar 6 menunjukkan hasil tahap *preprocessing* berupa konversi warna RGB menjadi citra *grayscale*. Pada tahap ini, saluran hijau digunakan sebagai acuan dalam penentuan nilai ambang pada proses segmentasi. Proses segmentasi dilakukan menggunakan metode ambang batas *Otsu*. Berdasarkan Citra 7(a), hasil segmentasi dengan metode *Otsu* belum mampu memisahkan objek dan latar belakang secara optimal karena masih terdapat *noise* yang terdeteksi sebagai bagian dari objek. Oleh karena itu, diperlukan penerapan operasi morfologi pada tahap selanjutnya untuk menghasilkan segmentasi yang lebih baik.



Gambar 7. Citra yang dihasilkan (a) Segmentasi, (b) *Bwareaopen*, (c) *Hole Filling*, (d) *Erosion*, (e) *Bwareaopen* Kedua, (f) *Dilation*

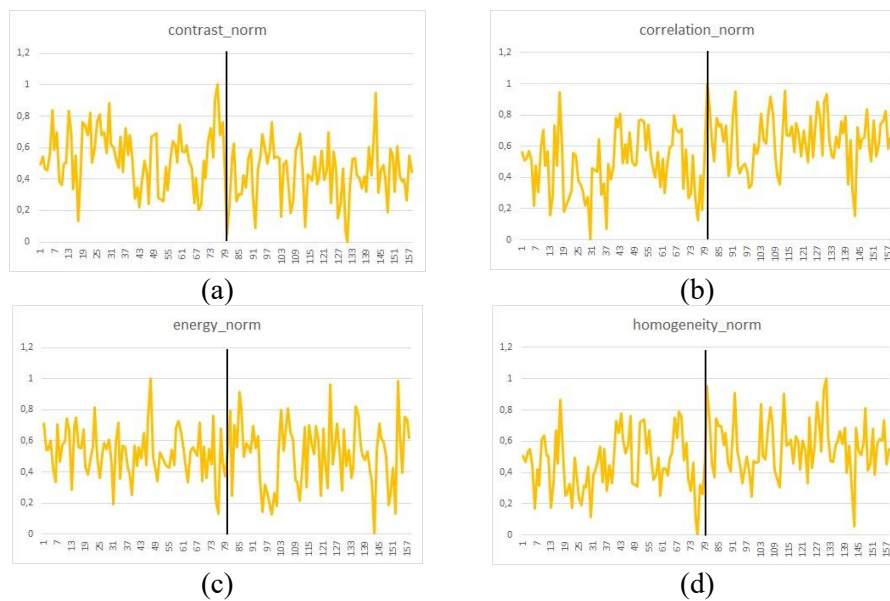
Pada Gambar 7(b), proses morfologi dimulai dengan operasi *bwareaopen* untuk menghilangkan komponen yang tidak diperlukan, seperti *noise* pada area latar belakang. Setelah itu, operasi *hole filling* dilakukan untuk menutupi celah atau lubang kecil pada objek. Hasil proses *hole filling* dapat dilihat pada Gambar 7(c), yang menunjukkan perbedaan jelas dibandingkan Gambar 7(b), khususnya pada bagian objek yang sebelumnya masih memiliki lubang kecil. Proses berikutnya adalah operasi *erosion* yang berfungsi mengurangi piksel pada tepi objek, dan hasilnya ditampilkan pada Gambar 7(d). Setelah *erosion*, operasi *bwareaopen* diterapkan kembali untuk membersihkan *noise* yang masih tersisa, sebagaimana terlihat pada Gambar 7(e). Tahap terakhir pada proses morfologi adalah operasi *dilation*, yang digunakan untuk menambahkan kembali piksel pada area tepi objek dan mengisi bagian yang terkikis selama proses *erosion*. Hasil *dilation* ditunjukkan pada Gambar 7(f).

Setelah diperoleh hasil segmentasi dan operasi morfologi yang optimal, tahap selanjutnya adalah melakukan ekstraksi fitur. Pada penelitian ini digunakan tiga jenis fitur, yaitu fitur warna, tekstur, dan bentuk. Pemilihan ketiga fitur tersebut didasarkan pada hasil eksperimen dari berbagai skenario kombinasi fitur. Hasil pengujian menunjukkan bahwa kombinasi fitur warna berbasis HSV, fitur tekstur yang mencakup nilai kontras, korelasi, energi, dan homogenitas, serta fitur bentuk yang meliputi luas, eksentrisitas, metrik, dan keliling menghasilkan tingkat akurasi yang lebih tinggi dibandingkan dengan skenario kombinasi fitur lainnya. Setiap fitur menghasilkan nilai input yang kemudian dinormalisasi untuk memperoleh nilai yang konsisten sehingga model dapat memahami dan menganalisis data dengan lebih mudah. Grafik nilai fitur warna HSV ditampilkan pada Gambar 8.

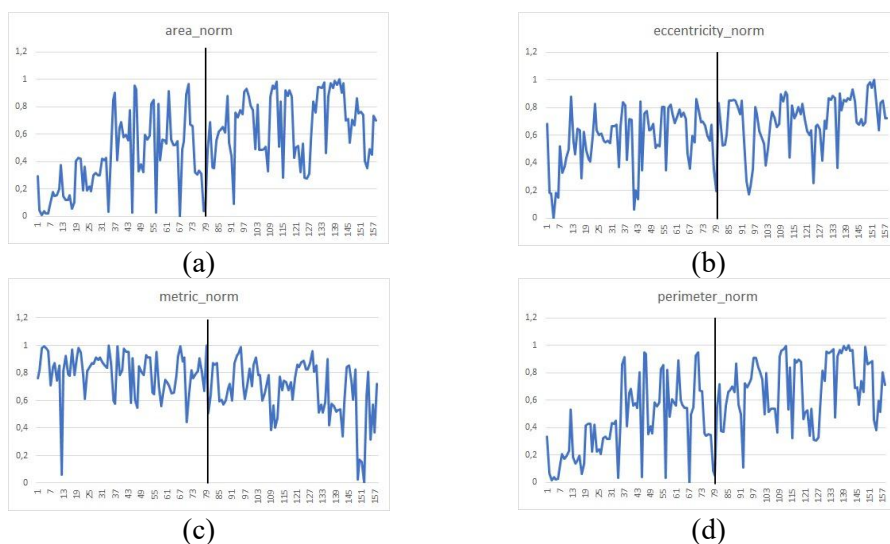


Gambar 8. Grafik Nilai Fitur Warna HSV

Berdasarkan grafik pada Gambar 8, nilai *hue* yang telah dinormalisasi pada kelas semangka hambar menunjukkan variasi yang cukup besar namun umumnya berada di bawah nilai 1. Sementara itu, pada semangka manis, nilai *hue* cenderung sedikit lebih tinggi meskipun tetap menunjukkan variasi. Grafik *saturation* terlihat relatif lebih rendah dan stabil pada semangka hambar dibandingkan dengan semangka manis yang memiliki nilai *saturation* lebih tinggi dan lebih bervariasi, mencerminkan intensitas warna yang lebih kuat yang sering dikaitkan dengan tingkat kematangan dan rasa manis [6]. Selain itu, nilai *value* yang dinormalisasi terlihat lebih tinggi pada semangka manis, menunjukkan warna yang lebih cerah atau lebih terang. Grafik nilai fitur tekstur dan bentuk masing-masing dapat dilihat pada Gambar 9 dan Gambar 10.



Gambar 9. Grafik Nilai Tekstur (a) Kontras, (b) Korelasi, (c) Energi, dan (d) Homogenitas



Gambar 10. Grafik Nilai Fitur Bentuk (a) Luas, (b) Eksentrisitas, (c) Metrik, dan (d) Keliling

Gambar 9 menunjukkan nilai fitur tekstur pada semangka hambar dan manis yang ditandai dengan garis pemisah. Grafik pada Gambar 9(a) memperlihatkan bahwa semangka hambar memiliki variasi kontras yang lebih besar dan fluktuasi yang tinggi, mencerminkan tekstur permukaan yang lebih kasar dan tidak rata. Sebaliknya, semangka manis memiliki nilai kontras yang lebih stabil dan cenderung lebih rendah, menandakan permukaan yang lebih halus. Gambar 9(b), yang menampilkan grafik nilai korelasi,

menunjukkan bahwa semangka hambar memiliki korelasi yang lebih rendah, yang mengindikasikan pola intensitas yang acak dan kurang teratur. Di sisi lain, semangka manis memiliki nilai korelasi yang lebih tinggi dan lebih stabil, mencerminkan tekstur yang lebih konsisten. Pada Gambar 9(c), grafik nilai energi memperlihatkan bahwa semangka hambar memiliki nilai energi yang lebih rendah dan kurang stabil, menunjukkan tekstur yang tidak seragam. Sementara itu, semangka manis memiliki nilai energi yang lebih tinggi dan stabil, menandakan pola yang lebih konsisten. Akhirnya, Gambar 9(d) menunjukkan bahwa semangka hambar memiliki nilai homogenitas yang lebih rendah, yang berarti perbedaan intensitas antarpiksel relatif besar. Sebaliknya, semangka manis menunjukkan nilai homogenitas yang lebih tinggi dan lebih stabil, yang menggambarkan tekstur permukaan yang lebih halus.


Berdasarkan Gambar 10, perbedaan nilai fitur bentuk antara semangka hambar dan manis dapat dilihat melalui empat aspek, yaitu luas, eksentrisitas, metrik, dan keliling. Pada semangka hambar, nilai luas pada Gambar 10(a) dan nilai keliling pada Gambar 10(d) menunjukkan variasi yang tinggi serta fluktuasi yang besar, yang mencerminkan ukuran dan bentuk yang kurang konsisten. Eksentrisitas semangka hambar pada Gambar 10(b) juga menunjukkan variasi yang cukup besar, mengindikasikan bentuk yang lebih tidak beraturan dibandingkan semangka manis. Nilai metrik pada Gambar 10(c) untuk semangka hambar tampak berfluktuasi tajam, menunjukkan tingkat ketidakteraturan bentuk yang lebih tinggi. Sebaliknya, semangka manis menunjukkan nilai yang lebih stabil pada keempat aspek tersebut. Luas, eksentrisitas, metrik, dan keliling memiliki rentang nilai yang lebih konsisten, sehingga mencerminkan bentuk yang lebih teratur, halus, dan seragam.

Setelah fitur berhasil diekstraksi, tahap selanjutnya adalah melakukan proses pelatihan dan pengujian dengan menggunakan berbagai kombinasi fitur. Tujuan utama dari tahap ini adalah menentukan kombinasi fitur yang paling optimal untuk mencapai akurasi tinggi sekaligus meminimalkan waktu komputasi. Hasil percobaan dari berbagai skenario kombinasi fitur ditampilkan pada Tabel 2.

Tabel 2. Perbandingan Akurasi dan Waktu Komputasi Skenario Kombinasi Fitur

Fitur	Akurasi (%)		Kesalahan Klasifikasi (%)		Waktu Komputasi (Detik)	
	Pelatihan	Pengujian	Pelatihan	Pengujian	Pelatihan	Pengujian
RGB	72.151	73.214	27.848	26.785	0.202	0.020
HSV	69.620	67.857	30.379	32.142	0.188	0.018
LAB	77.215	80.357	22.784	19.642	0.293	0.018
Rupa	72.151	55.357	27.848	44.642	0.215	0.018
Tekstur	51.265	57.142	48.734	42.857	0.186	0.020
RGB + Bentuk	85.443	64.285	14.557	35.714	0.193	0.023
RGB+Tekstur	76.528	58.928	23.417	41.071	0.205	0.020
LAB + Bentuk	85.443	66.071	14.557	33.928	0.213	0.023
LAB+Tekstur	85.075	58.928	13.924	41.071	0.240	0.019
HSV + Bentuk	83.544	73.214	16.455	26.785	0.214	0.020
HSV + Tekstur	75.949	62.500	24.050	37.500	0.262	0.022
Bentuk + Tekstur	87.341	51.785	12.658	48.214	0.328	0.020
RGB + Bentuk + Tekstur	81.645	67.857	18.354	32.142	0.219	0.023
<b>HSV + Bentuk + Tekstur</b>	<b>93.670</b>	<b>92.857</b>	<b>6.329</b>	<b>7.142</b>	<b>0.276</b>	<b>0.319</b>
LAB + Bentuk + Tekstur	93.670	66.071	6.329	33.928	0.270	0.023

Berdasarkan perbandingan nilai akurasi yang disajikan pada Tabel 2, skenario terbaik diperoleh dari kombinasi fitur warna berbasis HSV, fitur bentuk, dan fitur tekstur. Kombinasi ketiga fitur tersebut menghasilkan akurasi pelatihan sebesar 93,67% dengan tingkat kesalahan klasifikasi sebesar 6,32%, serta waktu komputasi sebesar 0.276 detik per citra. Pada tahap pengujian, akurasi pelatihan sebesar 93,67% dengan tingkat kesalahan klasifikasi sebesar 6,32%, serta waktu komputasi sebesar 92,85% dengan tingkat kesalahan klasifikasi 7,14% dan waktu komputasi sekitar 0,319 detik per citra. Sebanyak 158 data pelatihan dan 56 data pengujian kemudian diklasifikasikan menggunakan kombinasi fitur terbaik tersebut. Untuk mengevaluasi kinerja sistem klasifikasi secara lebih rinci, digunakan *confusion matrix* yang menggambarkan perbandingan antara label aktual dan hasil prediksi model. Visualisasi *confusion matrix* dapat dilihat pada gambar 11.



Gambar 11 Confusion Matrix Hasil Klasifikasi

Berdasarkan Gambar 11(a), model berhasil memprediksi 70 data pada kelas hambar dan 78 data pada kelas manis dengan benar dari total 79 data untuk masing-masing kelas. Terdapat beberapa kesalahan prediksi, yaitu sembilan data hambar yang diklasifikasikan sebagai manis dan satu data manis yang diklasifikasikan sebagai hambar. Pada Gambar 11(b), hasil klasifikasi untuk data pengujian menunjukkan bahwa 28 data hambar dan 24 data manis berhasil diprediksi dengan benar dari total 28 data per kelas. Tidak terdapat kesalahan prediksi pada kelas hambar, namun empat data pada kelas manis salah diklasifikasikan sebagai hambar. Hasil klasifikasi pada tahap pelatihan ditampilkan pada Tabel 3, sedangkan hasil pengujian disajikan pada Tabel 4.

Tabel 3. Hasil Klasifikasi Data Pelatihan

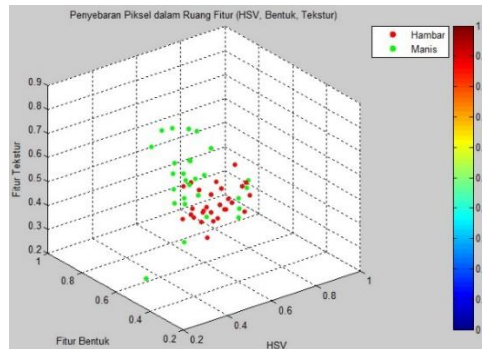
	Akurasi	Presisi	Recall	Skor F1
<b>Hambar</b>	93.67%	98.59%	88.60%	93.33%
<b>Manis</b>		89.65%	98.73%	93.97%

Tabel 4. Hasil Klasifikasi Data Pengujian

	Akurasi	Presisi	Recall	Skor F1
<b>Hambar</b>	92.85%	87.5%	100%	93.33%
<b>Manis</b>		100%	85.71%	92.30%

Berdasarkan data pada Tabel 3 menunjukkan hasil klasifikasi pada data pelatihan, di mana model mencapai akurasi sebesar 93,67%. Pada kelas hambar, diperoleh nilai presisi 98,59%, recall 88,60%, dan skor F1 sebesar 93,33%, yang menunjukkan bahwa sebagian besar data hambar dapat diprediksi dengan tepat meskipun masih terdapat beberapa kesalahan dalam mengenali seluruh data aktual. Sementara itu, pada kelas manis, model menghasilkan presisi 89,65%, recall 98,73%, dan skor F1 sebesar 93,97%, yang mengindikasikan kemampuan model yang sangat baik dalam mengenali data manis pada tahap pelatihan. Selanjutnya, Tabel 4 menyajikan hasil klasifikasi pada data pengujian dengan akurasi sebesar 92,85%, yang menunjukkan performa model tetap stabil pada data yang belum

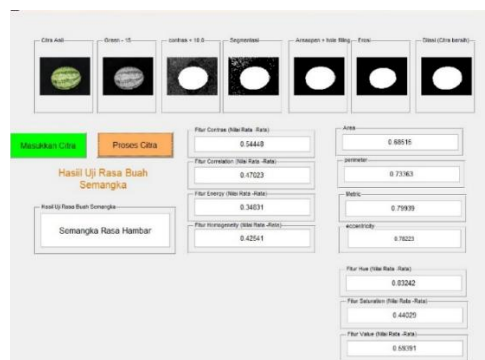
pernah dilihat sebelumnya. Pada kelas hambar, nilai presisi sebesar 87,5%, recall 100%, dan skor F1 sebesar 93,33% menunjukkan bahwa seluruh data hambar berhasil dikenali dengan benar, meskipun terdapat beberapa prediksi positif yang keliru. Pada kelas manis, diperoleh presisi 100%, recall 85,71%, dan skor F1 sebesar 92,30%, yang menandakan bahwa seluruh prediksi manis yang dihasilkan model benar, namun masih terdapat sebagian data manis yang salah diklasifikasikan sebagai hambar. Visualisasi distribusi hasil klasifikasi dapat dilihat pada Gambar 12.



Gambar 12. Visualisasi Distribusi, Bentuk, dan Tekstur Fitur Pikel HSV

Visualisasi ruang tiga dimensi pada Gambar 12 menunjukkan distribusi piksel dalam ruang fitur HSV, bentuk, dan tekstur untuk membedakan dua kelas semangka, yaitu manis dan hambar. Plot sebar tersebut memberikan gambaran umum mengenai pola distribusi kedua kelas. Meskipun sebagian besar data dari masing-masing kelas tampak terpisah, terdapat area tertentu di mana distribusi keduanya saling berdekatan. Dalam ruang fitur, komponen HSV memberikan kontribusi signifikan terhadap pemisahan kelas. Hal ini konsisten dengan keterkaitannya terhadap tingkat kematangan semangka, yang berpengaruh langsung pada intensitas warna kulit buah. Semangka manis cenderung memiliki nilai HSV yang lebih tinggi sehingga menunjukkan warna kulit yang lebih cerah, sedangkan semangka hambar umumnya memiliki nilai HSV yang lebih rendah.

Fitur bentuk dan tekstur juga memberikan informasi tambahan yang mendukung proses klasifikasi, meskipun kontribusinya tidak sekuat fitur HSV dalam memisahkan kelas. Fitur bentuk menggambarkan karakteristik geometris yang terkait dengan kondisi fisik buah, sedangkan fitur tekstur merepresentasikan variasi pola pada permukaan kulit semangka yang dapat berbeda antara semangka manis dan hambar. Meskipun distribusi piksel pada ruang fitur menunjukkan pemisahan kelas yang cukup baik, terdapat beberapa area yang tumpang tindih, menandakan adanya piksel dengan karakteristik serupa pada kedua kelas. Secara keseluruhan, visualisasi ini menunjukkan bahwa ruang fitur yang digunakan efektif dalam mengidentifikasi karakteristik visual yang membedakan rasa semangka. Antarmuka pengguna yang digunakan untuk melihat proses klasifikasi ditampilkan pada Gambar 13.



Gambar 13. Graphic User Interface (GUI)

Gambar 13 menampilkan antarmuka pengguna aplikasi MATLAB yang digunakan untuk melihat hasil pengujian dan nilai fitur citra semangka. Antarmuka terdiri atas beberapa bagian. Pada bagian atas, ditampilkan citra asli, hasil *preprocessing*, hasil segmentasi, serta proses morfologi yang digunakan untuk memperoleh citra yang bersih. Bagian lainnya menampilkan nilai fitur citra yang digunakan dalam proses pengujian. Pengguna dapat memasukkan citra dengan menekan tombol “Masukkan Citra”. Setelah citra berhasil dimuat, pengguna melanjutkan dengan menekan tombol “Proses Citra”, sehingga sistem akan memproses citra tersebut, menampilkan hasil setiap tahap pemrosesan hingga nilai fitur citra, dan memberikan hasil klasifikasi apakah citra terdeteksi sebagai semangka manis atau hambar.

#### 4. DISKUSI

Hasil penelitian menunjukkan bahwa sistem klasifikasi rasa semangka berbasis Jaringan Saraf Tiruan dengan kombinasi fitur warna, tekstur, dan bentuk mampu mencapai akurasi sebesar 93,67% pada data pelatihan dan 92,85% pada data pengujian. Capaian ini menunjukkan bahwa pendekatan yang diusulkan memiliki kemampuan generalisasi yang baik dalam membedakan rasa semangka manis dan hambar berdasarkan karakteristik visual kulit buah.

Jika dibandingkan dengan penelitian sebelumnya pada objek dan konteks yang serupa, performa sistem yang diusulkan menunjukkan keunggulan yang cukup signifikan. Penelitian yang menggunakan kombinasi fitur *Gray-Level Co-occurrence Matrix* dan *Support Vector Machine* pada semangka tanpa biji dilaporkan hanya mencapai akurasi sekitar 80%, yang mengindikasikan keterbatasan metode tersebut dalam menangkap kompleksitas hubungan antara tekstur kulit dan rasa buah. Sementara itu, penelitian lain yang memanfaatkan *Artificial Neural Network* untuk klasifikasi kandungan gula pada buah pisang dan pepaya mampu mencapai akurasi tinggi, yaitu 97,78% dan 100%, namun dengan waktu komputasi yang jauh lebih lama, masing-masing mencapai 375 detik hingga 1000 detik. Kondisi ini menunjukkan bahwa meskipun akurasi tinggi dapat dicapai, efisiensi komputasi menjadi kendala utama untuk implementasi praktis.

Pada penelitian ini, akurasi pengujian sebesar 92,85% dapat dicapai dengan waktu komputasi rata-rata hanya 0,319 detik per citra, yang secara signifikan lebih efisien dibandingkan pendekatan ANN dan *Deep Neural Network* pada penelitian sebelumnya. Sebagai perbandingan, metode *Deep Neural Network* yang digunakan untuk evaluasi rasa anggur meja dilaporkan menghasilkan akurasi 94,8%, namun membutuhkan dataset berukuran besar dan sumber daya komputasi tinggi selama proses pelatihan. Meskipun akurasi penelitian ini sedikit lebih rendah dibandingkan pendekatan *deep learning* tersebut, perbedaan kinerja yang relatif kecil tersebut diperoleh dengan arsitektur yang lebih sederhana dan biaya komputasi yang jauh lebih rendah, sehingga lebih sesuai untuk aplikasi dengan keterbatasan data dan perangkat keras.

Dari sisi pendekatan fitur, sebagian besar penelitian terdahulu hanya memanfaatkan fitur tunggal atau dua jenis fitur, seperti warna (RGB atau HSV) atau tekstur (GLCM) saja. Sebagai contoh, klasifikasi tingkat kemanisan alpukat berbasis fitur HSV dan *Support Vector Machine* dilaporkan mencapai akurasi 100%, namun hasil tersebut sangat bergantung pada kondisi pengambilan citra yang spesifik dan karakteristik buah tertentu. Sebaliknya, penelitian ini menggabungkan tiga jenis fitur visual utama, yaitu warna, tekstur, dan bentuk, sehingga mampu menangkap variasi visual semangka secara lebih komprehensif. Pendekatan multi-fitur ini terbukti meningkatkan stabilitas dan ketahanan model terhadap variasi visual, yang tercermin dari akurasi pengujian yang tetap tinggi.

Meskipun penelitian ini mengklasifikasikan rasa semangka dan bukan secara langsung tingkat kematangan buah, hasil yang diperoleh menunjukkan bahwa ciri visual eksternal dapat digunakan sebagai indikator tidak langsung dari rasa manis atau hambar. Dalam studi botani dan ilmu pangan, rasa manis semangka berkaitan erat dengan kandungan gula terlarut, yang terakumulasi selama proses fotosintesis dan distribusi nutrisi. Proses fisiologis tersebut memengaruhi warna hijau kulit, kontras pola

garis, serta tekstur permukaan buah, sehingga karakteristik visual dapat merefleksikan kondisi internal buah secara tidak langsung. Oleh karena itu, pendekatan klasifikasi berbasis citra digital yang digunakan dalam penelitian ini tidak bersifat trial-and-error, melainkan didukung oleh hubungan logis antara ciri visual dan rasa buah.

Secara keseluruhan, perbandingan dengan penelitian sebelumnya menunjukkan bahwa sistem yang diusulkan mampu mencapai keseimbangan yang baik antara akurasi dan efisiensi komputasi. Dengan akurasi pengujian di atas 92% dan waktu komputasi yang sangat rendah, pendekatan ini menawarkan solusi yang praktis dan aplikatif untuk sistem klasifikasi rasa buah berbasis citra digital, khususnya dalam konteks informatika terapan dan sistem cerdas non-destruktif.

## 5. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi rasa semangka berbasis pemrosesan citra digital menggunakan kombinasi fitur warna, tekstur, dan bentuk dengan algoritma Jaringan Saraf Tiruan metode *feedforward backpropagation*, yang mampu mengklasifikasikan semangka ke dalam kategori manis dan hambar dengan akurasi sebesar 93,67% pada data pelatihan dan 92,85% pada data pengujian, serta rata-rata komputasi 0,319 detik per citra. Hasil ini menunjukkan bahwa pemanfaatan kombinasi fitur visual memberikan representasi yang lebih komprehensif dibandingkan penggunaan fitur tunggal, sehingga mampu meningkatkan akurasi dan efisiensi sistem klasifikasi secara non-destruktif. Secara keilmuan, penelitian ini memberikan kontribusi pada bidang Informatika dan Ilmu Komputer dalam pengembangan sistem cerdas berbasis pengolahan citra digital dan pembelajaran mesin untuk aplikasi pertanian dan pangan, khususnya dalam penilaian kualitas buah secara objektif dan efisien. Penelitian selanjutnya dapat diarahkan pada peningkatan jumlah dataset, pemanfaatan metode pembelajaran mendalam seperti *Convolutional Neural Network* untuk ekstraksi fitur otomatis, serta integrasi sistem ke dalam platform mobile atau *Internet of Things* guna mendukung implementasi secara *real-time* di lingkungan praktis.

## REFERENSI

- [1] M. Afriansyah, J. Saputra, Y. Sa'adati, and Valian Yoga Pudya Ardhana, "Optimasi Algoritma Naive Bayes Untuk Klasifikasi Buah Apel Berdasarkan Fitur Warna RGB," *Bulletin of Computer Science Research*, vol. 3, no. 3, pp. 242–249, 2023, doi: 10.47065/bulletincsr.v3i3.251.
- [2] M. E. Putri, "Implementasi Tingkat Kemanisan Buah Semangka Berdasarkan Tekstur Kulit Buah Menggunakan Metode Ekstraksi Ciri Statistik," 2021.
- [3] M. A. Ikhsanudin, E. Setyati, and H. Junaedi, "Deteksi Tingkat Kemanisan Buah Semangka (*Citrullus Lanatus*) Berdasarkan Ciri Kulit Buah Dengan Menggunakan Metode CNN (Convolutional Neural Network)," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 4, pp. 1501–1513, 2023, doi: 10.29100/jupi.v8i4.4118.
- [4] J. Supriyanti, N. Karjunita, and K. Kuswandi, "Preferensi Konsumen Terhadap Kualitas Buah Semangka di Kabupaten Sijunjung," *Jurnal Agribisnis Unisi*, vol. 13, no. 1, pp. 1–8, 2024, doi: 10.32520/agribisnis.v11i1.1935.
- [5] J. Mashilo, H. Shimelis, R. M. Ngwepe, and Z. Thungo, "Genetic Analysis of Fruit Quality Traits in Sweet Watermelon (*Citrullus lanatus* var. *lanatus*): A Review," *Frontiers in Plant Science*, vol. 13, no. 3, pp. 1–14, 2022, doi: 10.3389/fpls.2022.834696.
- [6] D. R. Fernandes and N. Rachmat, "Klasifikasi Non-Destruktif Kemanisan Semangka Manohara Menggunakan Transfer Learning VGG-16," *Jurnal Teknologi dan Manajemen Industri Terapan*, vol. 4, no. 4, pp. 1330–1339, 2025, doi: 10.55826/81wv2s06.
- [7] C. Lanatus, D. I. Pasar, and K. Baru, "Analisis Preferensi Konsumen Terhadap Buah Semangka Merah Amara (*Citrullus Lanatus*) di Pasar Kota Baru Bojonegoro," *Jurnal AGRIFO*, vol. 9, no. 2, 2024, doi: 10.29103/ag.v9i2.19340.
- [8] E. F. Pratiwi, H. Rizqiati, and Nurwantoro, "Total Padatan Terlarut, Total Asam, CO<sub>2</sub>, Total Bakteri Asam Laktat, dan Organoleptik Water Kefir Semangka dengan Konsentrasi Sukrosa

- yang Berbeda,” *Jurnal Teknologi Pangan*, vol. 6, no. 2, pp. 8–13, 2022, doi: 10.14710/jtp.2022.24161.
- [9] N. H. Baco, A. A. Laya, and M. R. Buhang, “Pengaruh Pemberian Jus Semangka Merah Terhadap Tekanan Darah pada Dewasa Akhir di Kelurahan Mahawu Lingkungan VII,” *Jurnal Sains dan Kesehatan*, vol. 8, no. 1, 2024, doi: 10.57214/jusika.v8i1.553.
- [10] Statistik, “Produksi Buah-buahan dan Sayuran Menurut Jenis Tanaman Menurut Provinsi, 2023,” Badan Pusat Statistika.
- [11] M. Yusuf *et al.*, “Sistem Pakar Diagnosa Penyakit Pada Tanaman Semangka Merah Menggunakan Metode CNN Berbasis Android,” *JTS: Jurnal Teknik*, vol. 13, no. 1, pp. 99–109, 2024, doi: 10.31000/jt.v13i1.11830.
- [12] A. S. Mulyani and F. Utaningrum, “Lima Fitur Gray Level Co-Occurrence Matrix Untuk Deteksi Kemanisan Buah Semangka Tanpa Biji Dengan Klasifikasi Support Vector Machine Berbasis Raspberry Pi,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 6, pp. 2206–2213, 2021, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/9229>
- [13] A. A. Nurfitri, A. I. Kaparang, M. T. Hidayat, A. B. Kaswar, and D. D. Andayani, “Classification of the Level of Sugar Content in Papaya Fruit Based on Color Features Using Artificial Neural Network,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 6, pp. 1447–1456, 2023, doi: 10.52436/1.jutif.2023.4.6.733.
- [14] M. S, R. A. Burhan, T. Yuliarni, A. B. Kaswar, and D. D. Andayani, “Classification of Sugar Levels In Banana Fruit Based On Color Features Using Digital Image Processing-Based Artificial Neural Networks,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 6, pp. 1447–1456, 2023, doi: 10.52436/1.jutif.2023.4.6.733.
- [15] A. Qurrotul and F. Utaminingrum, “Rancang Bangun Deteksi Kemanisan Buah Semangka menggunakan Metode Gray Level Co-Occurrence Matrix dan Backpropagation Neural Network berbasis Raspberry Pi,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 2, pp. 707–712, 2022.
- [16] I. Jangcik, Sasmita, M. B. Billah, and Yuhelmi, “Penerapan Metode K-Nearest Neighbor Klasifikasi Jenis Buah Semangka dengan Image Processing,” *Jurnal Sistem Informasi*, vol. 5, no. 3, pp. 535–548, 2023, doi: 10.31849/zn.v5i3.16301.
- [17] Z. Liu, Y. Zhang, Y. Zhang, L. Guo, C. Wu, and W. Shen, “Evaluation of Table Grape Flavor Based on Deep Neural Networks,” *Applied Sciences (Switzerland)*, vol. 13, no. 11, 2023, doi: 10.3390/app13116532.
- [18] M. R. Saputra and H. Irsyad, “Klasifikasi Tingkat Kemanisan Alpukat Berdasarkan Fitur Hue Saturation Value (HSV) dengan Menggunakan Support Vector Machine (SVM),” *Jurnal Algoritme*, vol. 2, no. 2, pp. 113–119, 2022, doi: 10.35957/algoritme.v2i2.2361.
- [19] C. Chairati, N. Awalia, B. M. Jamaluddin, A. B. Kaswar, and S. Sasmita, “Klasifikasi Rasa Buah Salak Berdasarkan Warnas dan Bentuk Menggunakan Metode Jaringan Saraf Tiruan Berbasis Pengolahan Citra Digital,” *JUPI: Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, vol. 9, no. 3, pp. 1226–1235, 2024, doi: 10.29100/jupi.v9i3.5289.
- [20] J. C. Lapendy, A. A. C. Resky, H. Makmur, A. B. Kaswar, D. D. Andayani, and F. Adiba, “Klasifikasi Rasa Jeruk Siam Berdasarkan Warna Dan Tekstur Berbasis Pengolahan Citra Digital,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 2, pp. 756–767, 2024, doi: 10.29100/jupi.v9i2.5384.
- [21] H. S. Gill, O. I. Khalaf, Y. Alotaibi, S. Alghamdi, and F. Alassery, “Fruit Image Classification Using Deep Learning,” *Tech Science Press*, vol. 71, no. 3, pp. 5135–5150, 2022, doi: 10.32604/cmc.2022.022809.
- [22] Y. Gulzar, “Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique,” *Sustainability (Switzerland)*, vol. 15, no. 3, p. 1906, 2023, doi: 10.3390/su15031906.
- [23] X. Zhao, L. Zhao, and B. Cui, “Strategies and Mechanisms of Sweetness Enhancement,” *International Journal of Food Science and Technology*, vol. 60, no. 2, pp. 1–16, 2025, doi: 10.1093/ijfood/vvaf207.
- [24] S. Haryati *et al.*, *Budidaya semangka*. Kementrian Pertanian, 2022.

- 
- [25] E. I. Pratama, R. Dewati, and M. F. Anwar, "Preferensi Konsumen Buah Semangka Di Pasar Semangka Kecamatan Jebres Kota Surakarta," *Journal of Agribusiness, Social and Economic*, vol. 3, no. 1, pp. 1–8, 2023.
- [26] A. F. Setyowati, P. S. Wardani, E. R. Putri, D. R. P. S. Putri, and Y. R. Eko, "Pengolahan Citra Digital EKG Rumah Sakit Tk. IV Samarinda," *Progressive Physics Journal*, vol. 5, no. 1, pp. 343–349, 2024, doi: 10.30872/ppj.v5i1.1037.
- [27] F. A. P. Efran, Khairil, and J. Jumadi, "Implementasi Metode K-Means Clustering Pada Segmentasi Citra Digital," *Jurnal Media Infotama*, vol. 18, no. 2, pp. 291–301, 2022, doi: 10.37676/jmi.v18i2.2899.
- [28] P. Dhiman, A. Kaur, V. R. Balasaraswathi, Y. Gulzar, A. A. Alwan, and Y. Hamid, "Image Acquisition, Preprocessing and Classification of Citrus Fruit Diseases: A Systematic Literature Review," *Sustainability (Switzerland)*, vol. 15, no. 12, p. 9643, 2023, doi: 10.3390/su15129643.
- [29] B. Nurhannudin, "Perancangan Sistem Deteksi Tingkat Kemiringan Jalan Sederhana Dengan Metode Otsu Thresholding Menggunakan Colab," *Router: Jurnal Teknik Informatika dan Terapan*, vol. 2, no. 3, pp. 137–146, 2024, doi: 10.62951/router.v2i3.156.
- [30] R. N. J. S. Intam, A. Raihan, M. Alfajri, A. B. Kaswar, D. D. Andayani, and Asnidar, "Sistem Klasifikasi Jenis Sampah Berdasarkan Kombinasi Fitur Warnac Tekstur Menggunakan Artificial Neural Network Berbasis Pengolahan Citra Digital," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 2, pp. 411–420, 2024, doi: 10.25126/jtiik.20241128330.
- [31] G. B. Nugroho, R. Ananda, and P. Rosyani, "Identifikasi Obyek Benda Tajam Di Bandara Menggunakan Pengolahan Citra Digital Pada Citra X-Ray," *Jurnal AI dan SPK: Jurnal Artificial Intelegent dan Sistem Penunjang Keputusan*, vol. 1, no. 4, pp. 272–277, 2024, doi: 10.30870/VOLT.V1I1.815.
- [32] A. Fahla, A. Jalil, and R. Rahmadewi, "Segmentasi Citra Digital Ikan Menggunakan Metode Thresholding," *Jurnal Ilmiah Sains* vol. 10, no. 2, 2024, doi: 10.35799/jis.13.1.2013.2057.
- [33] M. Muchtar and R. A. Muchtar, "Perbandingan Metode Knn Dan Svm Dalam Klasifikasi Kematangan Buah Mangga Berdasarkan Citra Hsv Dan Fitur Statistik," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 2, pp. 876–884, 2024, doi: 10.23960/jitet.v12i2.4010.
- [34] R. Kurniawan, R. H. Nasution, S. Marwah, and B. Nasution, "Penerapan Metode Gray Level Co-Occurrence Matrix Dan Knn Untuk Mendeteksi Tingkat Kematangan Buah Mengkudu," *Journal of Science and Social Research*, vol. 4307, no. 2, pp. 765–772, 2024, doi: 10.54314/jssr.v7i2.1836.
- [35] C. C. Ukwuoma, Q. Zhiguang, B. Bin Heyat, L. Ali, Z. Almaspoor, and H. N. Monday, "Recent Advancements in Fruit Detection and Classification Using Deep Learning Techniques," *Hindawi*, vol. 2022, p. 29, 2022, doi: 10.1155/2022/9210947.
-