JIITU: JURNAL INOVASI INFORMATIKA DAN TEKNOLOGI INFORMASI
Agustus 2025, Volume: **01**, No. **02**| Pages **18–26**
doi: 10.25047/jiitu.v2i1.6060

ARTICLE

Identifikasi Varietas Mangga (Mangifera indica L.) Berdasarkan Citra Daun Menggunakan Neural Network

Identification of Mango Variety (Mangifera indica L.) Based on Leaf Image Using Neural Network

Raya Akbar Jaya, [1] Zilvanhisna Emka Fitri, [*2] Arizal Mujibtamala Nanda Imron, [3]

[1]Teknik Informatika, Jurusan Teknologi Informasi
[2]Teknologi Rekayasa Komputer, Jurusan Teknologi Informasi
[3]Teknologi Rekayasa Elektronika, Jurusan Teknik Elektro, Fakultas Teknik, Universitas Jember
*Penulis Korespondensi: zilvanhisnaef@polije.ac.id

(Disubmit 22-11-23; Diterima 23-3-24; Dipublikasikan online pada 30-3-24)

Abstrak

Banyaknya keanekaragaman varietas buah mangga dan persebarannya tidak selaras dengan kelengkapan dan kemudahan akses terkait informasinya. Saat ini pengkatagorian dan identifikasi varian tanaman menjadi salah satu masalah penelitian yang paling signifikan dalam domain pertanian. Fokus penelitian ini terletak pada identifikasi varietas mangga berdasarkan bentuk daun, karena daun pada setiap tanaman berbeda-beda dan dapat menipu mata manusia sehingga menyebabkan misklasifikasi pada tanaman. Maka dibutuhkan sistem otomatisasi yang bersifat obyektif dalam mengklasifikasi jenis daun mangga seperti metode klasifikasi backpropagation dan CNN. Hasil penelitian menunjukkan bahwa akurasi sistem metode backpropagation untuk 225 dataset mencapai 74.67%, sedangkan akurasi metode CNN mencapai 91.11% (VGG-16) dan 93.33% (MobileNet). Namun terjadi peningkatan akurasi saat dilakukan augmentasi data, sehingga menjadi 675 dataset. Hasil akurasi VGG-16 menjadi 96.30% dan akurasi MobileNet menjadi 95.56%.

Kata kunci: identifikasi; daun; mangga; neural network

Abstract

The large diversity of mango fruit varieties and their distribution is not in line with the completeness and ease of access to related information. Currently, the categorization and identification of plant variants is one of the most significant research problems in the agricultural domain. The focus of this research lies on identifying mango varieties based on leaf shape, because the leaves on each plant are different and can deceive the human eye, causing misclassification of plants. So an objective automation system is needed in classifying mango leaf types such as the backpropagation classification method and CNN. The results showed that the accuracy of the backpropagation method system for 225 datasets reached 74.67%, while the accuracy of the CNN method reached 91.11% (VGG-16) and 93.33% (MobileNet). However, there is an increase in accuracy when data augmentation is performed, so that it becomes 675 datasets. The result of VGG-16 accuracy becomes 96.30% and MobileNet accuracy becomes 95.56%.

Keywords: identification; leaf; mango; neural network

1. Pendahuluan

Negara Asia Tenggara atau lebih dikenal ASEAN sering mengekspor komoditas unggulan buah-buahan, salah satunya adalah buah mangga (*Mangifera indica L.*) [1]. Tinggi pohon mangga dapat mencapai lebih dari 10 meter dengan daun tunggal serta yang bentuk buahnya juga berbeda-beda. Perbedaan tersebut disebabkan karena mangga memiliki lebih dari 500 varietas namun diklasifikasi dengan 69 spesies berdasarkan variasi warna, bentuk daun dan bentuk buah [2]. Variasi mangga yang dikenal oleh masyarakat yaitu mangga arum manis, mangga golek, mangga gadung dan mangga manalagi. Permasalahan yang sering terjadi karena banyaknya keanekaragaman varietas buah mangga dan persebarannya tidak selaras dengan kelengkapan dan kemudahan akses terkait informasinya. Selama ini penelitian buah mangga berfokus pada penentuan tingkat kematangan dan klasifikasi varietas jenis mangga baik berdasarkan bentuk buah maupun daunnya. Saat ini pengkatagorian dan identifikasi varian tanaman menjadi salah satu masalah penelitian yang paling signifikan

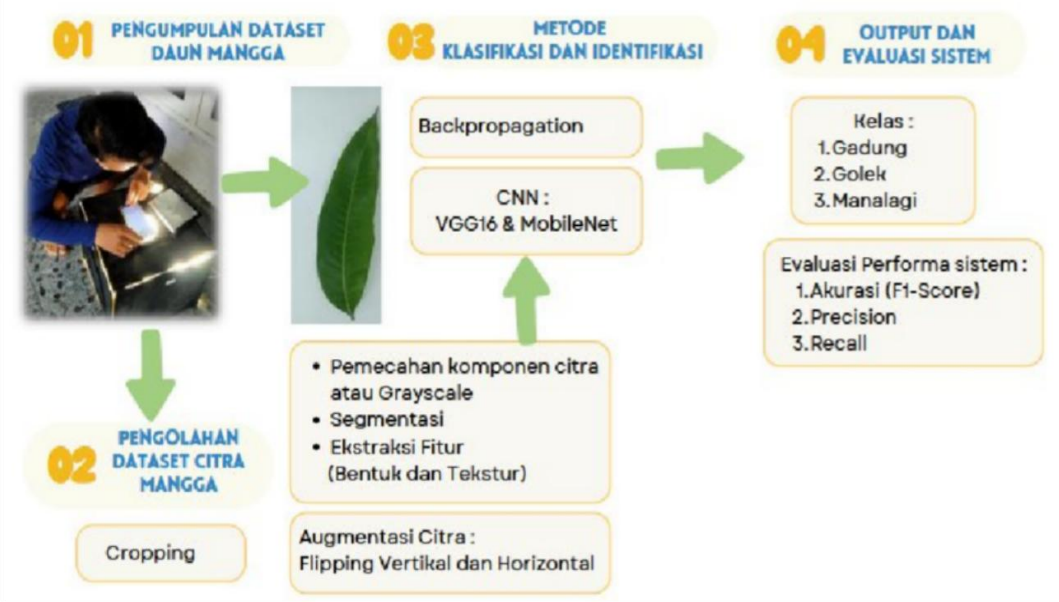
dalam domain pertanian[3]. Fokus penelitian ini terletak pada identifikasi varietas mangga berdasarkan bentuk daun, karena daun pada setiap tanaman berbeda-beda pada pola vena, bentuk, mid-rub, apex, lamina dan margin. Perubahan kecil ini dapat menipu mata manusia sehingga menyebabkan misklasifikasi pada tanaman. Pengenalan pola manusia berdasarkan bentuk, pengetahuan domain, ukuran, pola, dan warna tidak efisien, melelahkan, dan rentan terhadap kesalahan [4]. Berdasarkan permasalahan tersebut maka klasifikasi dan identifikasi varietas mangga berdasarkan daun membutuhkan sistem otomatisasi yang bersifat obyektif dalam mengklasifikasi jenis daun mangga berdasarkan karakteristiknya. Sistem tersebut nantinya dapat menjadi media penunjang yang membantu peneliti dan masyarakat luas dalam meningkatkan produksi atau membudidayakan varietas mangga unggulan baik untuk tujuan komersil atau pribadi [1], [5]. Computer Vision merupakan salah satu teknik yang umum digunakan dalam sistem otomatisasi pengenalan pola dari daun tanaman. Teknik tersebut mampu mengolah data berupa citra yang diambil oleh kamera digital atau smartphone[6], kemudian dikenali sebagai obyek kelas dalam penelitian oleh metode sistem cerdas.

Metode sistem cerdas yang digunakan seperti *K-Nearest Neighbor* (KNN) mampu mengklasifikasi jenis daun mangga (gadung, golek, manalagi dan podang) dengan tingkat akurasi optimal sebesar 87% pada K = 1 [7]. Metode *backpropagation neural network* (BPNN) mampu mengklasifikasi daun mangga manalagi dan mangga gadung dengan learning rate 0.9 dan maksimal epoh 100 menghasilkan akurasi sebesar 96% [8]. Metode *Radial Basis Function* (RBF) digunakan mengidentifikasi jenis mangga (gadung, manalagi dan podang) berdasarkan parameter warna HSV, luas area, perimeter, major axis dan minor axis dengan akurasi sebesar 53.12%[9]. *Support Vector Machine* (SVM) juga digunakan dalam mengklasifikasi daun mangga harum manis dan mangga manalagi menggunakan kernel *Gaussian Function* dengan akurasi sebesar 92.85%[10]. Keempat metode tersebut masih menggunakan teknik ekstraksi fitur tradisional seperti fitur warna, bentuk dan tekstur. Teknik tersebut memiliki kekurangan yaitu jika warna dan tekstur warna memiliki kemiripan antar kelas maka perlu adanya seleksi fitur untuk memaksimalkan tingkat akurasi sistem. Maka seiring dengan perkembangan metode cerdas khususnya pada metode neural network, dikembangkan metode *Convolutional Neural Network* (CNN). CNN sangat efektif dalam pengenalan citra, deteksi obyek dan segmentasi semantik menggunakan teknik konvolusi citra. Metode ini mampu mengklasifikasi jenis daun mangga (arumanis, golek dan manalagi) dengan akurasi sistem sebesar 85.59%[5]. Berbeda dengan penelitian yang dilakukan oleh [11] yang juga mengklasifikasi jenis daun yang sama namun terjadi peningkatan akurasi menjadi 89.20%.

Berdasarkan hasil dari penelitian terdahulu maka dipenelitian ini membandingkan metode cerdas backpropagation yang membutuhkan fitur dan metode CNN yang mengklasifikasikan kelas daun mangga berdasarkan hyperparameter dari teknik konvolusi citra. Penelitian tersebut diharapkan mampu mendapatkan tingkat akurasi yang optimal dalam mengklasifikasikan jenis mangga berdasarkan daunnya

2. Metode

Penelitian ini terdiri dari beberapa tahapan penelitian seperti pengumpulan dataset, pengolahan dataset, klasifikasi dan hasil kelas sebagai evaluasi sistem seperti yang ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Dataset

Dataset jenis daun mangga menggunakan data primer yang diambil menggunakan studio light box, background berwarna putih dan smartphone dengan jarak ± 25 cm seperti pada Gambar 1. Dataset tersebut terdiri dari tiga jenis mangga yaitu Mangga Golek, Mangga Gadung dan Mangga Manalagi yang masing-masing berjumlah 75 citra seperti Gambar 2.



Gambar 2. Contoh dataset jenis daun mangga

2.2 Pengolahan dataset

Pengolahan dataset menggunakan teknik pengolahan citra digital dengan beberapa teknik seperti cropping, pemecahan komponen citra, segmentasi dan ekstraksi fitur.

A. Cropping
Tahapan awal pengolahan dataset yaitu proses cropping untuk mengurangi background yang tidak dibutuhkan, tentu saja proses tersebut membantu mengurangi ukuran citra sehingga mengurangi beban komputasi [12]. Dari ukuran citra asli 4032 x 2268 piksel dicrop menjadi ukuran citra sebesar 301 x 121 piksel.

B. Augmentasi dataset
Teknik augmentasi bertujuan untuk memperbanyak variasi dataset, pada penelitian ini digunakan teknik *flipping.* Teknik ini menghasilkan citra berupa cerminan dari citra asli dari sumbu horizontal maupun vertikal [13] dengan persamaan rumus (1 – 2) :

$$Flipping\ Horizontal\ \left(X^{'}\right) = Width - 1 - x \quad (1)$$

$$Flipping\ Vertikal\ \left(Y^{'}\right) = Height - 1 - y \quad (2)$$

C. Pemecahan komponen citra dan Grayscale
Citra asli dari proses akuisisi data yang dihasilkan dari *smartphone* didapatkan ruang warna RGB, namun ruang warna RGB termasuk ruang warna yang besar yaitu 24 bit sehingga sulit untuk disegmentasikan [14] maka perlu dilakukan proses pemecahan komponen RGB menjadi channel red, channel green dan channel blue menggunakan kode pemrograman (1). Selain itu citra juga bisa dikonversi ke ruang warna grayscale menggunakan persamaan rumus (3).

Kode Pemrograman 1 :

```
red=(mangga(:,:,1));
green=(mangga(:,:,2));
blue=(mangga(:,:,3));
```

$$grayscale = \frac{red + green + blue}{3} \quad (3)$$

D. Segmentasi Citra
Tujuan dari segmentasi citra yaitu memisahkan obyek dan background pada citra menggunakan teknik *thresholding* untuk menghasilkan citra biner berdasarkan nilai ambang (T) dengan persamaan rumus (4) [1].

$$biner = \begin{cases} 1, \ grayscale\ (x,y) \geq T \\ 0, grayscale \quad x,y(< T \end{cases} \tag{4}$$

Untuk mendapatkan nilai T didasarkan pada nilai derajat keabuan di histogram citra.

E. Ekstraksi Fitur

Berdasakan citra biner yang dihasilkan dari proses segmentasi, selanjutnya diambil fitur khas yang mampu mengklasifikasi tiga kelas jenis daun mangga. Penelitian ini menggunakan fitur bentuk (panjang, lebar, area, perimeter, metric dan eccentricity) dan fitur tekstur (ASM, IDM, kontras dan entropi) dengan persamaan rumus (5 – 12) :

$$area = \sum piksel\ dari\ baris\ ke-1 + baris\ ke-2 + \ldots + baris\ ke-n \tag{5}$$

$$perimeter = \sum kode\ genap + \sqrt{2} \times \sum kode\ \ ganjil \tag{6}$$

$$metric = \frac{4\pi\ area}{perimeter} \tag{7}$$

$$eccentricity = \sqrt{\frac{(1 - minor\ axis^2)}{major\ axis^2}} \tag{8}$$

$$ASM = \sum_{x=1}^{L}\sum_{y=1}^{L} \left(GLCM(x,y)\right)^2 \tag{9}$$

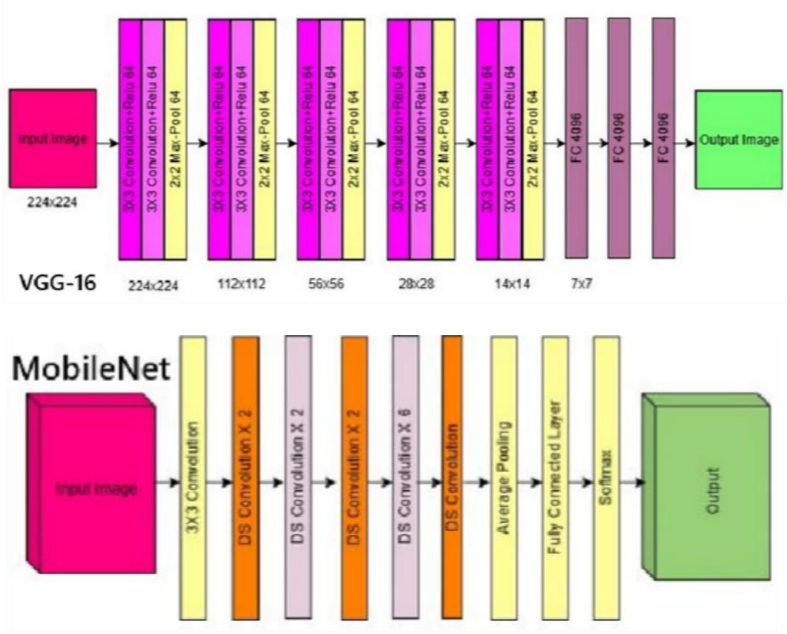
$$IDM = \sum_{x=1}^{L}\sum_{y=1}^{L} \frac{(GLCM\ \ (x,y)^2\ )}{1 + (x - y\ )^2} \tag{10}$$

$$kontras = \sum_{x=1}^{L}\sum_{y=1}^{L} |x - y|^2 GLCM(x,y) \tag{11}$$

$$Entropi = \sum_{x=1}^{L}\sum_{y=1}^{L} GLCM\left(x,y\right) logGLCM(x - y) \tag{12}$$

2.3 Metode Klasifikasi

Metode backpropagation merupakan salah satu metode jaringan syaraf tiruan atau *neural network* dimana proses pembelajarannya terawasi atau *supervised learning* [1]. *Supervised learning* adalah proses pembelajaran dimana model dilatih menggunakan dataset yang memiliki input dan output yang telah diketahui targetnya. Tujuannya adalah meminimalisir kesalahan klasifikasi dengan memperbarui bobot secara bertahap ketika sistem menghasilkan output yang tidak sama dengan target. Seiring dengan perkembangan, neural network juga mengalami pengembangan yaitu munculnya metode Convolutional Neural Network (CNN). Metode ini juga bagian dari *neural network,* namun input yang digunakan sistem bukan lagi parameter yang didapatkan dari proses ekstraksi fitur namun berdasarkan teknik konvolusi citra. Model CNN dibangun secara berurutan dengan lapisan-lapisan seperti *convolutional, maxpooling, flatten, dense* dan *dropout* menggunakan paramater *default* [15]. Beberapa contoh arsitektur CNN yang digunakan untuk klasifikasi yaitu VGG16 dan MobileNet. VGG16 adalah arsitektur *Convolutional Neural Network (CNN)* yang dikembangkan oleh tim Visual Geometry Group (VGG) di University of Oxford yang dikenal karena kesederhanaannya yang mendalam dan penggunaan filter konvolusi berukuran kecil (3×3) secara konsisten. VGG16 terdiri dari 16 lapisan yang dapat dilatih, yaitu 13 lapisan konvolusi dan 3 lapisan fully connected (FC) [16]. Sedangkan MobileNet dikembangkan oleh tim Google tahun 2017 yang dirancang dengan jumlah parameter yang besar namun dapat menghasilkan sistem yang ringan dan efisien [17].



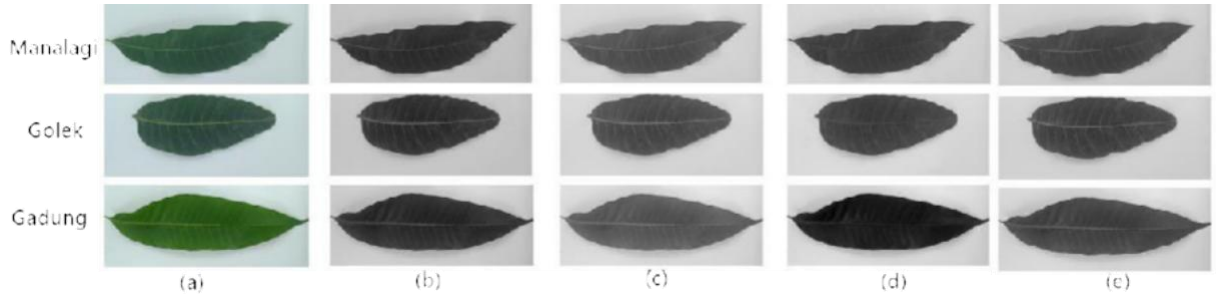
Gambar 3. Ilustrasi arsitektur VGG-16 dan MobileNet [18]

2.4 Evaluasi Performa Sistem

Evaluasi performa sistem bertujuan untuk mengukur keberhasilan serta kesesuaian sistem cerdas dalam mengklasifikasi dataset. Beberapa parameter yang digunakan untuk mengukur performa sistem yaitu akurasi, precision dan recall. Akurasi merupakan parameter yang mengukur proporsi prediksi yang benar dari seluruh jumlah prediksi yang dilakukan. Precision merupakan parameter yang mengukur seberapa tepat model saat memprediksi kelas positif dari semua yang diprediksi positif, berapa banyak yang benar. Recall mengukur seberapa lengkap model menemukan kelas positif dari semua yang seharusnya positif, berapa banyak yang ditemukan.

3. Hasil dan Pembahasan

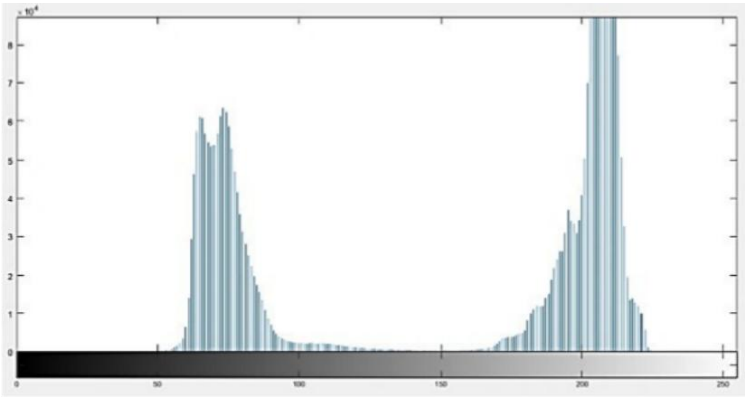
Pada penelitian ini dilakukan dua proses klasifikasi, pertama klasifikasi menggunakan metode backpropagation dan kedua menggunakan metode CNN. Metode backpropagation membutuhkan proses ekstraksi fitur untuk memproses data, sebelum dilakukan proses tersebut maka diperlukan teknik pengolahan citra digital, sedangkan metode CNN tidak membutuhkan proses tersebut. Maka citra hasil cropping dapat langsung diproses menggunakan klasifikasi CNN. Untuk teknik pengolahan citra digital setelah proses *cropping,* dilakukan proses pemecahan komponen RGB dibandingkan dengan konversi ke ruang warna *grayscale*. (1) daun mangga manalagi, (2) daun mangga golek dan (3) daun mangga gadung dilakukan proses pemecahan komponen menjadi (b) channel red, (c) channel green, (d) channel blue dan (e) citra grayscale yang ditunjukkan pada Gambar 4.



Gambar 4. (a) Citra asli, hasil pemecahan komponen (b) channel red, (c) channel green, (d) channel blue dan hasil (e) citra grayscale

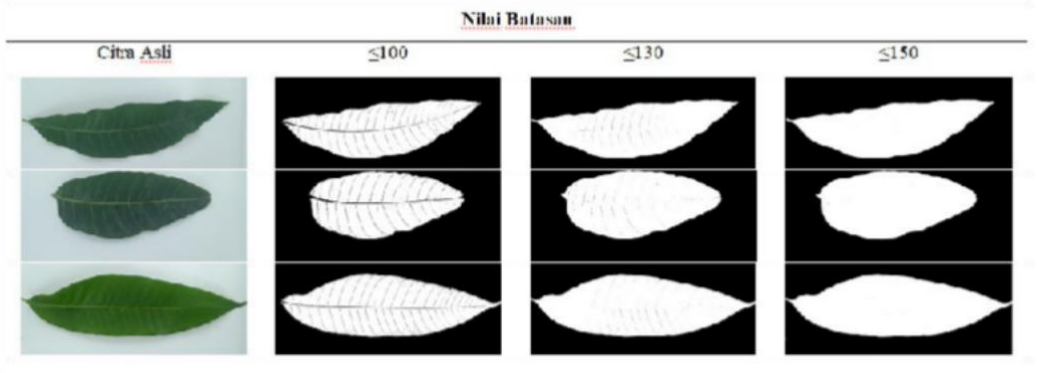
Berdasarkan Gambar 4, (b) citra channel red dan (d) citra channel blue menunjukkan adanya perbedaan yang signifikan antara area obyek dan area background yang jelas. (c) citra channel green juga menunjukkan area yang berbeda juga namun tulang daun dari masing-masing jenis daun mangga juga terlihat sehingga tekstur dari daun terlihat jelas, derajat keabuan area daun pada citra tersebut memiliki rentang nilai yang tidak jauh berbeda dengan derajat keabuan area background sehingga agak sulit untuk dilakukan proses segmentasi. Berbeda halnya dengan (e) citra grayscale, area daun lebih gelap dibandingkan dengan area background namun tekstur tulang daun masih terlihat. Maka citra grayscale dinilai paling baik dalam merepresentasikan bentuk dan tekstur daun mangga. Selanjutnya, proses segmentasi dilakukan untuk memisahkan obyek daun dan background citra menggunakan teknik *thresholding* dengan mencari nilai ambang (T) pada persamaan rumus

(2) sehingga didapatkan citra biner sebagai output dari proses segmentasi. Untuk mencari nilai ambang, maka citra histogram grayscale perlu dianalisis seperti yang ditunjukkan pada Gambar 5.



Gambar 5. Histogram citra grayscale

Gambar 5 menunjukkan bahwa pada histogram citra terdapat dua puncak gelombang ditunjukkan dengan dua range derajat keabuan yang berbeda. Derajat keabuan gelombang pertama di range 50 – 150 (kiri) dan range 150 – 230 (kanan) untuk derajat keabuan gelombang kedua. Gambar 4e menunjukkan jumlah piksel area background lebih banyak dibandingkan dengan jumlah piksel area daun serta derajat keabuan background mendekati warna putih (nilai grayscale = 255) sehingga dapat dipastikan bahwa area daun mempunyai range derajat keabuan 50 – 150. Maka penelitian ini berfokus pada nilai ambang T = 100, T = 130 dan T = 150 yang menghasilkan citra biner seperti pada Gambar 6 untuk dilanjutkan pada proses ekstraksi fitur.



Gambar 6. Hasil citra biner berdasarkan nilai ambang (T)

Berdasarkan Gambar 6, nilai ambang (T) yang menghasilkan citra biner dengan bentuk daun paling baik adalah nilai T ≤ 150. Nantinya citra biner tersebut digunakan untuk proses ekstraksi fitur bentuk sementara untuk citra nilai T ≤ 100 menghasilkan citra dengan menampilkan tekstur pola tulang daun yang paling baik sehingga sangat cocok untuk diekstraksi fitur tekstur. Ekstraksi fitur bentuk menggunakan persamaan rumus (5 - 8) sedangkan ekstraksi fitur tekstur menggunakan persamaan rumus (9 - 12) sehingga mendapatkan nilai yang dijabarkan pada Tabel 1.

Tabel 1. Nilai mean ekstraksi fitur bentuk dan tekstur berdasarkan kelas daun mangga

Parameter		Kelas		
		Golek	Gadung	Manalagi
Panjang (major axis length)		1763,4	1706,42	1720,84
Lebar (minor axis length)		512,44	528,38	583,16
Area		760586,1	760257,4	809639,7
Perimeter		4214,04	4328,22	4093
Metric		0,532684	0,502864	0,576894
Eccentricity		0,956544	0,955348	0,938732
GLCM 0°	ASM	0,6905	0,6854	0,6791
	IDM	0,9978	0,9982	0,9977
	Kontras	0,0043	0,0036	0,0046
	Entropi	0,5046	0,5083	0,5169
GLCM 45°	ASM	0,6883	0,6835	0,6771
	IDM	0,9967	0,9972	0,9967
	Kontras	0,0066	0,0055	0,0066
	Entropi	0,5156	0,5179	0,5266
GLCM 90°	ASM	0,6901	0,6848	0,6789
	IDM	0,9976	0,9979	0,9976
	Kontras	0,0048	0,0042	0,0048
	Entropi	0,5068	0,5110	0,5178

Parameter		Kelas		
		Golek	Gadung	Manalagi
GLCM 135°	ASM	0,6882	0,6834	0,6768
	IDM	0,9967	0,9972	0,9965
	Kontras	0,0066	0,0056	0,0069
	Entropi	0,5160	0,5184	0,5280

Hasil dari ekstraksi fitur bentuk dan tekstur menjadi input dari metode backpropagation yang berjumlah 22 fitur. Data yang digunakan sebagai data latih yaitu 150 citra daun yang terdiri dari 50 daun pada masing-masing kelas. Sedangkan parameter dari metode backpropagation seperti variasi learning rate (α), maksimal epoh sebanyak 100 epoh dan terdapat dua hidden layer yang dilakukan variasi sehingga didapatkan perbandingan tingkat akurasi seperti Tabel 2.

Tabel 2. Perbandingan akurasi pelatihan sistem berdasarkan variasi arsitektur jaringan dan learning rate

Arsitektur jaringan				Learning rate (α)		
Input	Hidden Layer (1)	Hidden Layer (2)	Output	0,1	0,2	0,3
22	10	5	3	76,6	74,67	70
22	10	6	3	80	74	71
22	10	7	3	74	71	69

Berdasarkan Tabel 2 menunjukkan dengan akurasi pelatihan sistem sebesar 80% yang didapatkan dari arsitektur backpropagation 22,10,6,3 dan learning rate α = 0.1. learning rate dan arsitektur tersebut digunakan untuk menguji akurasi sistem didapatkan tingkat akurasi sebesar 74.67% pada learning rate α = 0.1, 69% pada α = 0.2 dan 58% pada α = 0.3 seperti yang ditunjukkan pada Tabel 3 dan hasil confusion matriks (Gambar 4).

Tabel 3. Perbandingan hasil akurasi pengujian sistem berdasarkan variasi learning rate

Arsitektur jaringan				Learning rate (α)		
Input	Hidden Layer (1)	Hidden Layer (2)	Output	0,1	0,2	0,3
22	10	6	3	74,67	69	58

		Predict		
		Golek	Gadung	Manalagi
Actual	Golek	14	6	5
	Gadung	4	19	2
	Manalagi	0	2	23

Gambar 7. Confusion Matriks

Gambar 7 menunjukkan bahwa terjadi banyak misklasifikasi utamanya citra yang seharusnya mangga golek namun sistem misklasifikasi menjadi kelas mangga gadung sebanyak 6 citra dan 5 citra sebagai mangga manalagi. Sedangkan kelas mangga manalagi juga mempunyai kemiripan dengan kelas mangga gadung karena dari 25 citra masih terdapat 2 citra yang misklasifikasi.

Untuk membandingkan metode klasifikasi lain, citra asli hasil cropping menjadi input dari metode klasifikasi CNN dengan arsitektur VGG16 dan MobileNet. Sebelumnya, citra input hasil dari proses cropping dilakukan proses augmentasi menggunakan teknik *flipping* horizontal maupun vertikal yang bertujuan untuk memperbanyak jumlah variasi citra daun. Hasil output dari teknik ini jumlah citra daun mangga dari 225 data menjadi 675 data. Selanjutnya citra tersebut dilakukan proses pembagian dataset 70% data latih : 20% data testing : 10% data validation dengan learning rate (α =0.01) dan variasi epoh (10,30,50) sehingga didapatkan akurasi yang optimal dari sistem baik menggunakan metode VGG16 dan MobileNet (Tabel 4).

Tabel 4. Akurasi Sistem VGG-16 dan MobileNet

Epoch	VGG-16		MobileNet	
	(a)	(b)	(a)	(b)
10	80	81.48	84.44	84.44
30	91.11	94.81	82.22	94.81
50	91.11	96.30	93.33	95.56

Keterangan :
(a) $\sum dataset = 225$
(b) $\sum dataset = 675$

Tabel 4 menunjukkan bahwa semakin besar jumlah dataset, metode CNN semakin baik dalam mengenal pola. Hal tersebut dibuktikan dengan peningkatan tingkat akurasi sistem baik arsitektur VGG-16 maupun MobileNet pada variasi epoh (banyaknya iterasi) dalam proses pelatihan. Akurasi terbaik VGG-16 terjadi pada maksimal

epoh = 50 baik pada dataset 225 data menghasilkan sebesar 91.11% sedangkan pada dataset 675 data, akurasi sistem meningkat menjadi 96.30%. Hal ini juga selaras dengan akurasi MobileNet pada maksimal epoh = 50, akurasi sistem pada dataset 225 data mencapai 93.33% sedangkan pada dataset 675 data mencapai 95.56%. Proses selanjutnya adalah evaluasi sistem untuk mendapatkan perbandingan performa backpropagation, VGG-16 dan MobileNet seperti yang ditunjukkan pada Tabel 5.

Tabel 5. Perbandingan performa sistem metode cerdas

Parameter	Backpropagation	VGG-16	MobileNet
Akurasi	74.67	96.30	95.56
Precision	74.67	96.33	96.33
Recall	75.03	96.33	94.67

Tabel tersebut menunjukkan bahwa metode CNN dengan arsitektur VGG-16 adalah metode klasifikasi yang paling optimal dan akurat dalam mengidentifikasi jenis daun mangga dengan akurasi sebesar 96.30%. sedangkan metode backpropagation memiliki akurasi sistem sebesar 74.67%. hal ini dipengaruhi oleh pemilihan fitur pada proses ekstraksi fitur.

4. Simpulan

Berdasarkan hasil penelitian yang telah dilakukan maka metode backpropagation maupun CNN mampu dengan baik mengklasifikasi dan mengidentifikasi jenis buah mangga berdasarkan citra daun. Namun pada metode backpropagation harus dilakukan seleksi fitur baik pada fitur bentuk maupun fitur tekstur. Sedangkan metode CNN mampu mengklasifikasi lebih baik ketika jumlah dataset lebih dari 100 data tiap kelas. Banyaknya data turut berperan serta dalam proses pengenalan pola pada sistem cerdas. Untuk pengembangan penelitian selanjutnya, perlu adanya perbanyakan dataset serta teknik preprocessing untuk meningkatkan performa dari metode CNN baik arsitektur VGG-16 maupun MobileNet

DAFTAR PUSTAKA

[1] Z. E. Fitri, R. Aprilia, A. Madjid, and A. M. N. Imron, "Ensiklopedia Digital Berdasarkan Klasifikasi Varietas Buah Mangga (Mangifera spp.) Menggunakan Algoritma Backpropagation," *Komputika : Jurnal Sistem Komputer*, vol. 11, no. 2, pp. 113–120, Feb. 2022, doi: 10.34010/komputika.v11i2.5513.

[2] Fitrianingsih and Rodiah, "KLASIFIKASI JENIS CITRA DAUN MANGGA MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 3, pp. 223–238, 2020, doi: 10.35760/tr.2020.v25i3.3519.

[3] T. Aslam *et al.*, "Machine learning approach for classification of mangifera indica leaves using digital image analysis," *Int J Food Prop*, vol. 25, no. 1, pp. 1987–1999, Dec. 2022, doi: 10.1080/10942912.2022.2117822.

[4] N. Truong Minh Long and N. Truong Thinh, "Using Machine Learning to Grade the Mango's Quality Based on External Features Captured by Vision System," *Applied Sciences*, vol. 10, no. 17, p. 5775, Aug. 2020, doi: 10.3390/app10175775.

[5] D. Hidayat, "Klasifikasi Jenis Mangga Berdasarkan Bentuk Dan Tekstur Daun Menggunakan Metode Convolutional Neural Network(CNN)," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 5, no. 1, pp. 98–103, 2022.

[6] R. Saleem, J. H. Shah, M. Sharif, M. Yasmin, H.-S. Yong, and J. Cha, "Mango Leaf Disease Recognition and Classification Using Novel Segmentation and Vein Pattern Technique," *Applied Sciences*, vol. 11, no. 24, p. 11901, Dec. 2021, doi: 10.3390/app112411901.

[7] A. A. Triono, "Sistem Pengenalan Jenis Mangga Berdasarkan Daun Metode K-Nearest Neighbor," *Simki-Techsain*, vol. 1, no. 8, pp. 3–11, 2017.

[8] F. Nur Fajri and R. Anggi Pramunendar, "PENGENALAN VARIETAS MANGGA BERDASARKAN BENTUK DAN TEKSTUR DAUN MENGGUNAKAN METODE BACKPROPAGATION NEURAL NETWORK," *Jurnal
Teknologi Informasi*, vol. 13, no. 2, pp. 143–153, 2017, [Online]. Available: http://research.

[9] R. Mahadyanto, D. A. Prastiningtyas, and F. E. Purwiantono, "Penerapan Metode Jaringan Syaraf Tiruan Radial Basis Function Untuk Identifikasi Jenis Mangga Berdasarkan Pola Daun," *Journal of Information and Technology (J-Intech)*, vol. 7, no. 1, pp. 90–96, 2019.

[10] G. Isnansyah, K. A. Ngii, and R. Adi Saputra, "Klasifikasi Citra Daun Mangga Menggunakan Algoritma Support Vector Machine," *Kopertip : Jurnal Ilmiah Manajemen Informatika dan Komputer*, vol. 7, no. 3, pp. 80–83, Mar. 2024, doi: 10.32485/kopertip.v7i3.346.

[11] Fitrianingsih and Rodiah, "Klasifikasi Jenis Citra Daun Mangga Menggunakan Convolutional Neural Network," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 3, pp. 223–238, Dec. 2020, doi: 10.35760/tr.2020.v25i3.3519.

[12] B. Adi Prasetya *et al.*, "Ensiklopedia Digital Varietas Ubi Jalar Berdasarkan Klasifikasi Citra Daun

Menggunakan K-Nearest Neighbor," *Elektrika*, vol. 14, no. 1, pp. 1–6, 2022.
[13] P. Oza, P. Sharma, S. Patel, F. Adedoyin, and A. Bruno, "Image Augmentation Techniques for Mammogram Analysis," *J Imaging*, vol. 8, no. 5, p. 141, May 2022, doi: 10.3390/jimaging8050141.
[14] Z. E. Fitri, R. Rizkiyah, A. Madjid, and A. M. N. Imron, "Penerapan Neural Network untuk Klasifkasi Kerusakan Mutu Tomat," *Jurnal Rekayasa Elektrika*, vol. 16, no. 1, May 2020, doi: 10.17529/jre.v16i1.15535.
[15] R. Mardianto, Stefanie Quinevera, and S. Rochimah, "Perbandingan Metode Random Forest, Convolutional Neural Network, dan Support Vector Machine Untuk Klasifikasi Jenis Mangga," *Journal of Applied Computer Science and Technology*, vol. 5, no. 1, pp. 63–71, May 2024, doi: 10.52158/jacost.v5i1.742.
[16] Bella Dwi Mardiana, Wahyu Budi Utomo, Ulfah Nur Oktaviana, Galih Wasis Wicaksono, and Agus Eko Minarno, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 1, pp. 20–26, Feb. 2023, doi: 10.29207/resti.v7i1.4550.
[17] A. Taner, M. T. Mengstu, K. Ç. Selvi, H. Duran, İ. Gür, and N. Ungureanu, "Apple Varieties Classification Using Deep Features and Machine Learning," *Agriculture*, vol. 14, no. 2, p. 252, Feb. 2024, doi: 10.3390/agriculture14020252.
[18] S. Vidivelli, P. Padmakumari, C. Parthiban, A. DharunBalaji, R. Manikandan, and A. H. Gandomi, "Optimising deep learning models for ophthalmological disorder classification," *Sci Rep*, vol. 15, no. 1, p. 3115, Dec. 2025, doi: 10.1038/s41598-024-75867-3.