

KLASIFIKASI JENIS DURIAN BERDASARKAN CITRA DAUN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR VGG-16

Ahmad Haikal Nuqqy Zahhar^{1*}, I Gede Susrama Mas Diyasa², Made Hanindya Prami Swari³

^{1,2,3} Informatika, Universitas Pembangunan Nasional "Veteran" Jawa Timur

²igsusrama.if@upnjatim.ac.id

³madehanindya.fik@upnjatim.ac.id

*Corresponding author email: ahmadhaikalnuqqyzahhar@gmail.com

Abstrak— Durian (*Durio zibethinus Murr*) merupakan komoditas hortikultura lokal Indonesia yang memiliki potensi ekonomi sangat tinggi. Namun, kualitas durian lokal masih dihadapkan pada permasalahan kurangnya perawatan optimal yang berdampak pada penurunan harga jual. Permasalahan ini muncul karena terbatasnya pengetahuan petani dalam memilih varietas durian yang tepat untuk dikembangkan. Identifikasi yang akurat terhadap jenis durian menjadi kunci utama dalam meningkatkan kualitas serta nilai ekonomis buah tersebut. Studi taksonomi menunjukkan bahwa ciri morfologi daun dapat dijadikan penanda taksonomi yang reliabel untuk mengidentifikasi spesies tanaman.

Proses identifikasi jenis durian melalui pengamatan daun secara konvensional memerlukan keahlian khusus dan waktu yang tidak singkat, selain itu sangat dipengaruhi oleh subjektivitas pengamat. Di Kabupaten Nganjuk, terdapat tiga varietas durian yang banyak dibudidayakan yaitu durian lokal, durian lai, dan durian montong yang memiliki karakteristik daun mirip sehingga sulit diidentifikasi secara visual. Penelitian terdahulu belum ada yang secara khusus mengkaji klasifikasi varietas durian menggunakan citra daun dengan pendekatan deep learning, sehingga terdapat kesenjangan penelitian yang perlu dieksplorasi untuk mendukung pertanian presisi di Indonesia.

Penelitian ini mengimplementasikan metode Convolutional Neural Network (CNN) dengan arsitektur VGG-16 untuk mengklasifikasikan varietas durian berdasarkan citra daun. Dataset berjumlah 600 gambar terdistribusi merata untuk tiga kelas: montong, lokal, dan lai. Melalui preprocessing dan augmentasi data, dataset ditingkatkan menjadi 2400 gambar. Pengujian dilakukan melalui 16 skenario dengan empat pembagian dataset dan empat optimizer (SGD, Adam, Adamax, Adagrad). Model terbaik menghasilkan akurasi 97,08% dengan pembagian data 90:10 dan optimizer Adam, menunjukkan sistem mampu mengklasifikasi varietas durian dengan sangat akurat.

Kata Kunci— Daun Durian, Deep Learning, CNN, Arsitektur VGG-16

I. PENDAHULUAN

Durian (*Durio zibethinus Murr*) merupakan aset genetik tanaman lokal Indonesia bernilai ekonomi tinggi yang dikenal sebagai "raja buah" di Asia Tenggara [1]. Indonesia memiliki ragam jenis durian melimpah yang dibudidayakan secara turun-

temurun dan diregistrasikan ke Pusat PVTTP untuk menjamin kelestariannya.

Data BPS menunjukkan produksi durian nasional mencapai 1,13 juta ton (2020), dengan Jawa Timur sebagai produsen terbesar (24,34%). Namun, kualitas durian lokal masih terkendala minimnya perawatan akibat keterbatasan pemahaman petani dalam memilih jenis durian sesuai karakteristik lingkungan setempat, sehingga berdampak pada penurunan nilai jual.

Identifikasi akurat jenis durian menjadi faktor krusial untuk meningkatkan kualitas dan nilai ekonomis. Morfologi daun dapat menjadi indikator taksonomi yang andal untuk identifikasi spesies tanaman [2]. Struktur daun durian memperlihatkan pola venasi, bentuk, tekstur, dan ukuran yang khas untuk setiap varietas sehingga dapat dijadikan landasan klasifikasi [3]. Morfologi daun spesies Durio memiliki karakteristik pembeda signifikan, termasuk bentuk lamina, tipe venasi, dan tekstur permukaan daun [4].

Namun, identifikasi manual memerlukan keahlian khusus, memakan waktu, dan rentan terhadap subjektivitas. Di Kabupaten Nganjuk, tiga jenis durian populer (lokal, lai, montong) sulit dibedakan secara visual karena kemiripan daun. Belum ada kajian spesifik tentang klasifikasi jenis durian berbasis citra daun menggunakan deep learning, sehingga terdapat celah penelitian untuk mendukung pertanian presisi di Indonesia.

Kemajuan teknologi computer vision dan deep learning membuka prospek otomatisasi identifikasi tanaman berdasarkan citra daun. CNN dengan arsitektur VGG-16 telah terbukti efektif dalam klasifikasi citra tanaman [5]. Kebaruan penelitian ini terletak pada penerapan CNN VGG-16 dengan 16 skenario pengujian untuk klasifikasi jenis durian lokal Indonesia, yang belum pernah dilakukan sebelumnya dan berpotensi memberikan kontribusi substansial bagi teknologi pertanian presisi. Melalui metode CNN dan algoritma VGG-16, penelitian ini diharapkan menghasilkan model klasifikasi jenis durian berdasarkan citra daun dengan akurasi optimal, sekaligus berfungsi sebagai alat bantu membedakan jenis durian dengan karakteristik daun yang mirip.

II. LITERATUR REVIEW

A. Penelitian Terdahulu

Perkembangan computer vision dan deep learning membuka peluang besar dalam klasifikasi tanaman otomatis menggunakan CNN. Beberapa penelitian terdahulu menunjukkan efektivitas arsitektur VGG-16:

- 1) *Thomkaew dan Intakosum* [6]: Klasifikasi 10 kelas daun tomat (9 sakit, 1 sehat) menggunakan VGG-16 dengan akurasi 99,27%. Optimasi mengurangi parameter dan waktu komputasi tanpa mengorbankan performa, menunjukkan efektivitas VGG-16 untuk deteksi penyakit tanaman.
- 2) *Rajab et al.* [7]: Perbandingan VGG-16 dan VGG-19 untuk klasifikasi 5 varietas anggur dari 500 gambar daun. VGG-16 mencapai akurasi 99,6%, VGG-19 mencapai 100%. Memvalidasi morfologi daun sebagai basis reliable untuk identifikasi varietas dengan efisiensi tinggi.
- 3) *Asriny dan Jayadi* [8]: Implementasi CNN VGG-16 untuk klasifikasi kualitas jeruk siam dari 1000 gambar dalam 5 kelas kualitas dengan akurasi 97,50%. Mendemonstrasikan adaptabilitas VGG-16 untuk berbagai klasifikasi produk pertanian.

B. Landasan Teori

1) Morfologi Daun Durian sebagai Karakter Diagnostik

Penelitian taksonomi mengindikasikan bahwa karakteristik morfologi daun dapat menjadi indikator yang andal untuk identifikasi spesies tanaman [2]. Pada durian, struktur daun memperlihatkan pola venasi, bentuk, tekstur, dan ukuran yang khas untuk setiap varietas, sehingga dapat dijadikan landasan klasifikasi yang akurat [3].[4] morfologi daun spesies Durio memiliki karakteristik pembeda yang signifikan, termasuk diantaranya:

- a) Bentuk lamina : Variasi dari elliptic hingga oblong
- b) Tipe venasi : Pola percabangan pembuluh daun yang distinctive
- c) Tekstur permukaan : Karakter pubescence dan surface roughness
- d) Dimensi daun : Rasio panjang-lebar yang konsisten per varietas

2) CNN) Convolutional Neural Network

CNN adalah pengembangan Multilayer Perceptron (MLP) untuk data 2D seperti gambar, dikategorikan sebagai Deep Neural Network. CNN mampu mempertahankan informasi spasial gambar, pertama kali diperkenalkan sebagai NeoCognitron oleh Kunihiko Fukushima. Arsitektur CNN terdiri dari tiga komponen utama:

- a) *Convolutional Layer*: Convolutional layer terdiri dari neuron yang tersusun sehingga membentuk sebuah filter dengan panjang dan tinggi. Melakukan operasi konvolusi menggunakan filter (kernel) untuk mendeteksi fitur-fitur lokal dalam citra. Operasi matematis konvolusi didefinisikan sebagai:

$$O(m, n) = \sum \sum I(i, j) \times K(m - i, n - j) \quad (1)$$

Dalam persamaan (1) menyatakan:

$O(m,n)$: output feature map

$I(i,j)$: input image

K : convolutional kernel

m,n : spatial dimensions

- b) *Pooling Layer*: Pooling Layer melakukan downsampling untuk menjaga ukuran data dan mengontrol overfitting. Max pooling memilih nilai maksimum pada daerah tertentu sambil mempertahankan informasi penting.
- c) *Fully Connected Layer*: Fully connected layer berfungsi mengklasifikasi data masukan. Keluaran dari pooling layer yang masih berbentuk multidimensional array diubah menjadi vektor melalui proses flatten sebelum menjadi input untuk fully connected layer.

3) Arsitektur VGG-16

VGG-16 dikembangkan oleh Visual Geometry Group, University of Oxford, meraih peringkat kedua di ImageNet 2014. Terdiri dari 16 layer (13 convolutional + 3 fully connected). Karakteristik kunci:

- a) *Consistent Filter Size* : Menggunakan filter 3×3 konsisten dengan computational cost lebih rendah
- b) *Deep Architecture* : 5 blok konvolusi dengan max pooling setelah setiap blok
- c) *Parameter Configuration* : ~138 juta parameter, input size $224 \times 224 \times 3$, klasifikasi 1000 classes

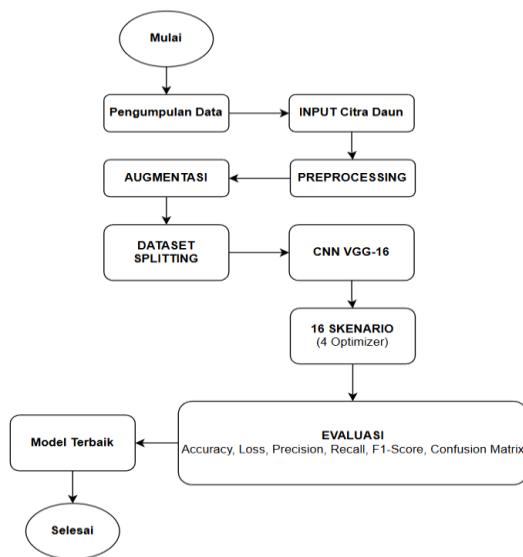
4) Optimizer

Optimizer adalah algoritma untuk meminimalkan fungsi kerugian (loss function) dalam pelatihan model machine learning dengan cara memperbarui parameter model (bobot dan bias) berdasarkan nilai gradien. Tujuannya agar prediksi model lebih akurat. Contoh optimizer: SGD, Adam, Adamax, dan Adagrad [11].

III. METODE PENELITIAN

A. Model yang diusulkan

Dalam penelitian ini dataset yang digunakan adalah data privat, citra daun durian yang terdiri dari 3 jenis yaitu montong, Lai dan lokal. Dataset DurianLeaf yang telah dikumpulkan selanjutnya akan dilakukan preprocessing dan augmentasi. Metode klasifikasi yang digunakan adalah CNN dengan arsitektur VGG-16. Dalam penelitian ini dilakukan 16 skenario pengujian untuk memperoleh model terbaik sehingga memperoleh hasil klasifikasi citra daun durian terbaik pada tiga class yaitu local, lai dan montong.

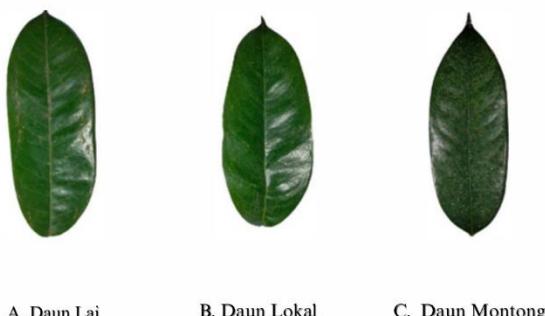


Gbr. 1 Model yang diusulkan

B. Pengumpulan Data

Pengumpulan data menggunakan metode *purposive sampling* dengan target 200 citra per jenis durian (Lokal, Lai, Montong), total 600 citra. Standar pengambilan: kamera minimal 2048x2048 piksel, background putih, jarak 30cm ± 2cm, pencahayaan natural pagi hari (08:00-10:00, 500-800 lux), dan sudut tegak lurus. Lokasi pengambilan di tiga kebun durian Kabupaten Nganjuk dengan bantuan petani berpengalaman minimal 15 tahun. Kriteria sampel: daun sehat, dewasa penuh (*mature*), bebas kerusakan fisik, dan representatif karakteristik morfologi jenis durian.

CITRA DAUN DURIAN



Gbr. 2 Original image

IV. HASIL DAN PEMBAHASAN

A. Dataset

Dalam penelitian ini dataset yang digunakan adalah data privat berupa citra daun durian. Dataset yang dikumpulkan sebanyak 600 citra dengan komposisi berimbang yaitu 200 citra dari

masing-masing class, montong, lai dan local. Karakteristik dataset dapat dilihat pada Tabel 1.

TABEL 1
KOMPOSISI DATASET DURIANLEAF

Jenis Durian	Jumlah Citra	Percentase	Resolusi Rata-rata	Quality Score*
Durian Lokal	200	33.33%	2048x2048	0.89 ± 0.05
Durian Lai	200	33.33%	2048x2048	0.91 ± 0.04
Durian Montong	200	33.34%	2048x2048	0.88 ± 0.06
Total	600	100%	2048x2048	0.89 ± 0.05

*Quality Score berdasarkan *sharpness*, *contrast*, dan *background uniformity* (skala 0-1)

Proses validasi dataset melibatkan tiga expert independen menghasilkan inter-annotator reliability yang tinggi dengan Fleiss' kappa = 0.87, menunjukkan substantial agreement dalam identifikasi jenis durian. Distribusi quality scores menunjukkan konsistensi tinggi dengan standard deviation rendah (0.04-0.06), mengonfirmasi standardisasi yang efektif dalam proses pengumpulan data.

B. Preprocessing

Dataset DurianLeaf yang telah diperoleh, selanjutnya akan dilakukan tahapan preprocessing. Dalam tahap ini akan dilakukan Resizing. Citra di-resize ke 224x224 piksel menggunakan bilinear interpolation, tujuannya untuk mendapatkan ukuran citra yang seragam.

Kemudian tahapan Normalisasi, Nilai piksel dinormalisasi ke rentang [0,1] dengan pembagian RGB/255.0. Langkah terakhir dari preprocessing adalah Standardisasi, Mean subtraction dan scaling menggunakan ImageNet statistics (mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]). Selanjutnya akan diperolah hasil citra Dataset DurianLeaf setelah preprocessing.



A. Original image

B. Resized (224,224)



C. Normalize [0,1]

D. Contras Enhanced (CLAHE)

Gbr. 3 Original image

C. Augmentasi

Augmentasi dilakukan untuk memperbanyak dataset DurianLeaf yang terbatas agar lebih beragam. Proses augmentasi meliputi: rotasi acak $\pm 30^\circ$, horizontal flip (probabilitas 48,8%), penyesuaian kontras $\pm 50,1\%$, dan pergeseran width/height $\pm 12\%$. Hasilnya, dataset meningkat 4x lipat dari 600 citra asli menjadi 2400 citra (600 asli + 1800 hasil augmentasi).

D. Pembagian Dataset

Setelah diperoleh hasil dari augmentasi, dataset sebanyak 2400, dibagi dalam empat pembagian dalam 16 skenario model pengujian. Pembagian tersebut diantaranya 90:10, Dimana komposisi 90% dataset untuk training dan 10% untuk test. Pembagian data 80:20, dengan komposisi 80% untuk data training dan 20% untuk test. Pembagian 70:30 dengan komposisi 70% data training dan 30% data test. Keempat 60:40, dengan komposisi 60% data training dan 40% data test. Pembagian dataset ini bertujuan untuk memperoleh model terbaik dari 16 skenario pengujian.

TABEL 2
PEMBAGIAN DATASET

Split	Montong		Lai		Lokal	
	Training	Test	Training	Test	Training	Test
90:10	720	80	720	80	720	80
80:20	640	160	640	160	640	160
70:30	560	240	560	240	560	240
60:40	480	320	480	320	480	320

E. Skenario Pengujian

Skenario pengujian dalam penelitian mengacu pada rencana dan rancangan penelitian dalam pengumpulan data, menganalisis informasi dan Menyusun Kesimpulan yang didasarkan pada hasil penelitian. Dalam penelitian ini melakukan 16 skenario pengujian dengan metode CNN arsitektur VGG-16. Menggunakan 4 optimizer yaitu SGD (Stochastic Gradient Descent) , Adagrad , Adam (Adaptive Moment Estimation) dan AdaMax. Split data untuk training dan testing yang digunakan adalah perbandingan 90:10, 80:20. 70:30 dan 60:40. Nilai epoch yang dipilih adalah 1-5 dengan tujuan untuk memperoleh model Skenario pengujian terbaik. Hasil dari 16 Skenario pengujian tersebut terbagi dalam 4 dataset splitting berikut:

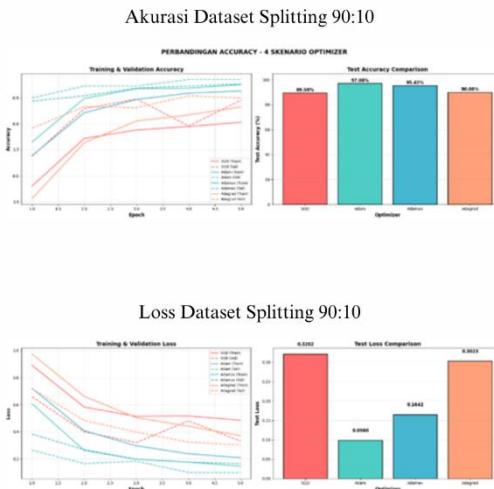
1) Dataset splitting 90:10

Dalam Skenario pengujian ini dataset dibagi dalam 90% data training dan 10% data testing, dari keseluruhan 2400 dataset terbagi dalam 2160 data training, atau masing-masing kelas berjumlah 720 dataset. Sedangkan untuk data testing sebanyak 240 dataset atau 80 dataset pada masing-masing class. Berikut perbandingan hasil dari *dataset splitting* 90:10

TABEL 3
PERBANDINGAN HASIL PADA DATASET SPLITTING 90:10

Skenario	Optimizer	Akurasi	Loss	Time	Epoch
Skenario 1	SGD	89.58%	0.3202	1.54 min	5
Skenario 2	Adam	97.08%	0.0980	1.11 min	5
Skenario 3	Adamax	95.42%	0.1642	1.17 min	5
Skenario 4	Adagrad	90.00%	0.3023	1.15 min	5

Evaluasi performa empat optimizer (SGD, Adam, Adamax, Adagrad) pada dataset splitting 90:10. Bagian atas menampilkan grafik kurva training dan validation accuracy (kiri) selama 5 epoch dengan rentang 0.0-1.0, serta bar chart test accuracy (kanan): SGD 89.58%, Adam 97.08%, Adamax 95.42%, Adagrad 90.00%. Bagian bawah menampilkan grafik kurva training dan validation loss (kiri) dengan rentang 0.0-4.0, serta bar chart test loss (kanan): SGD 0.3202, Adam 0.0980, Adamax 0.1642, Adagrad 0.3023. Optimizer Adam menunjukkan performa terbaik dengan akurasi tertinggi dan loss terendah pada proporsi data training terbesar (90%).



Gbr. 4 Perbandingan Akurasi dan loss Dataset Splitting 90:10

2) Dataset splitting 80:20

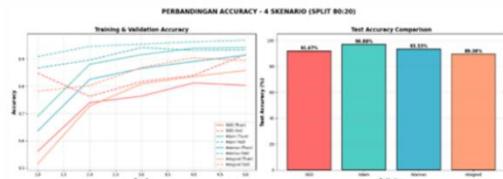
Dalam Skenario pengujian ini dataset dibagi dalam 80% data training dan 20% data testing, dari keseluruhan 2400 dataset terbagi dalam 1920 data training, atau masing-masing kelas berjumlah 640 dataset. Sedangkan untuk data testing sebanyak 480 dataset atau 160 dataset pada masing-masing class. Berikut perbandingan hasil dari *dataset splitting* 80:20

TABEL 4
PERBANDINGAN HASIL PADA DATASET SPLITTING 80:20

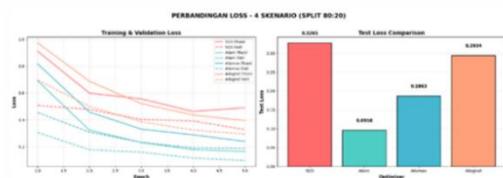
Skenario	Optimizer	Akurasi	Loss	Time	Epoch
Skenario 1	SGD	91.67%	0.3265	1.13 min	5
Skenario 2	Adam	96.88%	0.0958	1.14 min	5
Skenario 3	Adamax	93.33%	0.1863	1.13 min	5
Skenario 4	Adagrad	89.38%	0.2934	1.12 min	5

Evaluasi performa empat optimizer (SGD, Adam, Adamax, Adagrad) pada dataset splitting 80:20. Bagian atas menampilkan grafik kurva training dan validation accuracy (kiri) selama 5 epoch dengan rentang 0.0-1.0, serta bar chart test accuracy (kanan): SGD 91.67%, Adam 96.88%, Adamax 93.33%, Adagrad 89.38%. Bagian bawah menampilkan grafik kurva training dan validation loss (kiri) dengan rentang 0.0-3.5, serta bar chart test loss (kanan): SGD 0.3265, Adam 0.0958, Adamax 0.1863, Adagrad 0.2934. Optimizer Adam menunjukkan performa terbaik dengan kemampuan robust mempertahankan akurasi tinggi meskipun proporsi data testing lebih besar (80:20).

Akurasi Dataset Splitting 80:20



Loss Dataset Splitting 80:20



Gbr. 5 Perbandingan Akurasi dan Loss Dataset Splitting 80:20

3) Dataset splitting 70:30

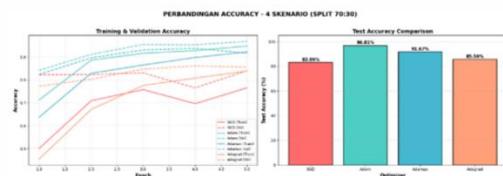
Dalam Skenario pengujian ini dataset dibagi dalam 70% data training dan 30% data testing, dari keseluruhan 2400 dataset terbagi dalam 1680 data training, atau masing-masing kelas berjumlah 560 dataset. Sedangkan untuk data testing sebanyak 720 dataset atau 240 dataset pada masing-masing class. Berikut perbandingan hasil dari dataset splitting 70:30

TABEL 5
PERBANDINGAN HASIL PADA DATASET SPLITTING 70:30

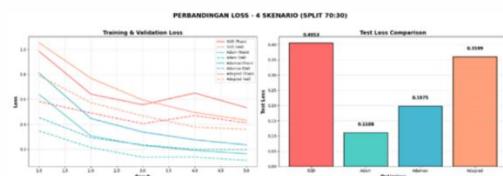
Skenario	Optimizer	Akurasi	Loss	Time	Epoch
Skenario 1	SGD	83.06%	0.4053	1.11 min	5
Skenario 2	Adam	96.81%	0.1108	1.15 min	5
Skenario 3	Adamax	91.67%	0.1975	1.31 min	5
Skenario 4	Adagrad	85.56%	0.3599	1.18 min	5

Evaluasi performa empat optimizer (SGD, Adam, Adamax, Adagrad) pada dataset splitting 70:30. Bagian atas menampilkan grafik kurva training dan validation accuracy (kiri) selama 5 epoch dengan rentang 0.0-1.0, serta bar chart test accuracy (kanan): SGD 83.06%, Adam 96.81%, Adamax 91.67%, Adagrad 85.56%. Bagian bawah menampilkan grafik kurva training dan validation loss (kiri) dengan rentang 0.0-4.0, serta bar chart test loss (kanan): SGD 0.4053, Adam 0.1108, Adamax 0.1975, Adagrad 0.3599. Optimizer Adam menunjukkan performa terbaik dengan kemampuan robust mempertahankan akurasi tinggi meskipun proporsi data testing lebih besar (70:30).

Akurasi Dataset Splitting 70:30



Loss Dataset Splitting 70:30



Gbr. 6 perbandingan Akurasi dan loss dataset splitting 70:30

4) Dataset splitting 60:40

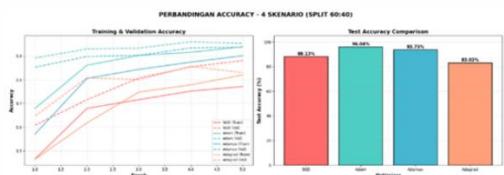
Dalam Skenario pengujian ini dataset dibagi dalam 60% data training dan 40% data testing, dari keseluruhan 2400 dataset terbagi dalam 1440 data training, atau masing-masing kelas berjumlah 480 dataset. Sedangkan untuk data testing sebanyak 960 dataset atau 320 dataset pada masing-masing class. Berikut perbandingan hasil dari dataset splitting 60:40

TABEL 6
PERBANDINGAN HASIL PADA DATASET SPLITTING 60:40

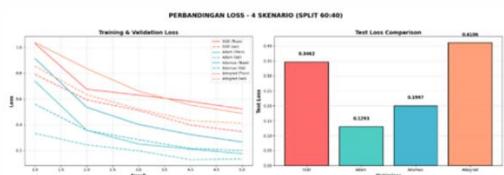
Skenario	Optimizer	Akurasi	Loss	Time	Epoch
Skenario 1	SGD	88.13%	0.3462	1.08 min	5
Skenario 2	Adam	96.04%	0.1293	1.13 min	5
Skenario 3	Adamax	93.75%	0.1997	1.13 min	5
Skenario 4	Adagrad	83.02%	0.4106	1.11 min	5

Evaluasi performa empat optimizer (SGD, Adam, Adamax, Adagrad) pada dataset splitting 60:40. Bagian atas menampilkan grafik kurva training dan validation accuracy (kiri) selama 5 epoch dengan rentang 0.0-1.0, serta bar chart test accuracy (kanan): SGD 88.13%, Adam 96.04%, Adamax 93.75%, Adagrad 83.02%. Bagian bawah menampilkan grafik kurva training dan validation loss (kiri) dengan rentang 0.0-3.5, serta bar chart test loss (kanan): SGD 0.3462, Adam 0.1293, Adamax 0.1997, Adagrad 0.4106. Optimizer Adam menunjukkan performa terbaik dengan kemampuan luar biasa mempertahankan akurasi tinggi dalam kondisi paling challenging dengan data training minimum (60%) dan data testing maksimum (40%).

Akurasi Dataset Splitting 60:40



Loss Dataset Splitting 60:40



Gbr. 7 perbandingan Akurasi dan loss dataset splitting 60:40

F. Model Terbaik

Setelah dilakukan 16 skenario pengujian dengan 4 dataset splitting yang berbeda yaitu 90:10, 80:20, 70:30 dan 60:40 serta 4 optimizer yaitu SGD, Adam, Adamax dan Adagrad. Model terbaik tertuju pada Skenario 2 dimana komposisi pengujian terdiri dari dataset splitting 90:10, menggunakan optimizer adam. Nilai epoch 5 dengan waktu pengujian 1.11 menit.

TABEL 7
PERBANDINGAN HASIL SEMUA SKENARIO PENGUJIAN

Skenario	Optimizer	Akurasi	Loss	Split	Epoch
1	SGD	89.58%	0.3202	90:10	5
2	Adam	97.08%	0.0980		5
3	Adamax	95.42%	0.1642		5
4	Adagrad	90.00%	0.3023		5
5	SGD	91.67%	0.3265	80:20	5
6	Adam	96.88%	0.0958		5
7	Adamax	93.33%	0.1863		5
8	Adagrad	89.38%	0.2934		5
9	SGD	83.06%	0.4053	70:30	5
10	Adam	96.81%	0.1108		5
11	Adamax	91.67%	0.1975		5
12	Adagrad	85.56%	0.3599		5
13	SGD	88.13%	0.3462	60:40	5
14	Adam	96.04%	0.1293		5
15	Adamax	93.75%	0.1997		5
16	Adagrad	83.02%	0.4106		5

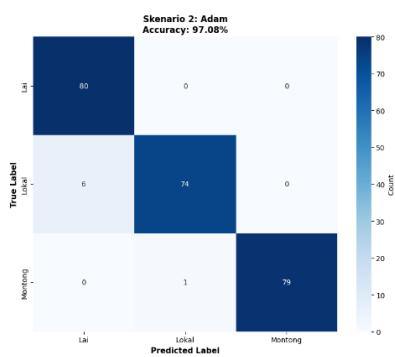
Hasil skenario 2 menggunakan rasio split data 90:10 dari total 2400 dataset hasil augmentasi (2160 data training dan 240 data testing) dengan masing-masing 800 dataset untuk 3 kelas (Montong, Lai, dan Lokal). Model menggunakan optimizer Adam dengan learning rate 0,01, 5 epoch, dropout 0,5, dan dense layer 256 unit. Training time 1,11 menit dengan akurasi 97,08%.

TABEL 8
NILAI HASIL PADA SKENARIO MODEL 2

Class	precision	recall	FI-score	Accuracy
Lai	0.93	1.00	0.96	0.97
Lokal	0.99	0.92	0.95	
Montong	1.00	0.98	0.99	

Hasil Confusion matrix untuk skenario pengujian model 2 dapat dilihat bahwa, dari keseluruhan 240 data testing, model ini dapat mengklasifikasi sebanyak 233 data dengan nilai benar (true). Sebanyak 7 data mengalami kegagalan dalam proses

klasifikasinya. Dari proses ini dapat digambarkan sejauh mana model mampu mengidentifikasi dengan benar terhadap kelas-kelas objek dan distribusi hasil prediksi pada keseluruhan data testing.



Gbr. 8 Confusion Matrix pada Skenario Model 2

V. KESIMPULAN

Dari pembahasan dan hasil dalam penelitian ini, sebanyak 600 dataset durianleaf yang diperoleh, dengan sebaran sebanyak 200 dataset dari masing-masing class montong, lai, local. Dilakukan preprocessing dan augmentasi sehingga dataset mengalami peningkatan sebanyak 4 x menjadi 2400. Penerapan 16 skenario model pengujian menggunakan metode klasifikasi CNN dengan arsitektur VGG-16 dan strategi 4 split data serta 4 optimizer yaitu SGD, Adam, Adamax dan Adagrad. Model terbaik terletak pada Skenario pengujian 2, Dimana nilai akurasi tertinggi didapatkan sebesar 97.08%. split dataset 90:10 , optimizer Adam dan waktu pengujian 1.11 menit menunjukkan hasil klasifikasi jenis durian berdasarkan citra daun yang terbaik.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada keluarga yang senantiasa mendukung penulis dalam setiap aktivitas. Terima kasih disampaikan pula untuk seluruh sahabat dan semua pihak yang mendukung penulis dalam semua rangkaian penelitian dan penyusunan laporan ini.

REFERENSI

- [1] Siti Sehat Tan. (2022). "Keragaman Durian (Durio Zibenthimus Murr) Lokal Indonesia Dengan Kasus Durian Orange dan Buntut Ali." *Jurnal Ilmiah Respati* Vol. 13, No. 1 Juni 2022
- [2] Hickey, M., & King, C. (2000) "The Cambridge Illustrated Glossary of Botanical Terms" Cambridge University Press
- [3] Corner, 1988; Kostermans & Bompard, 1993 " The Mangoes: Their Botany, Nomenclature, Horticulture and Utilization." Academic Press Limited ISBN-10: 0-12-421920-9.
- [4] Martha Adiwaty Sihaloho (2021). " Morphological Characters of Local Origin Durian (Durio zibethinus Murr.) Fruits and Seeds from Central Tapanuli Regency, North Sumatra, Indonesia." *International Journal on Advanced Science Engineering Information Technology.* (2021). Vol.11(1). ISSN: 2088-5334.
- [5] Smith, J. A., & Johnson, B. C. (2020). "Deep Learning for Plant Disease Detection: A Review." *Journal of Agricultural AI*, 5(2), 123-135.
- [6] Jiraporn Thomkaew, Sarun I, " Improvement Classification Approach in Tomato Leaf Disease using Modified Visual Geometry Group (VGG)-InceptionV3", (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 13, No. 12, 2022
- [7] Maha A Rajab, et.al, "Classification of grapevine leaves images using VGG-16 and VGG-19 deep learning nets" *TELKOMNIKA Telecommunication Computing Electronics and Control* Vol. 22, No. 2, April 2024, pp. 445~453
- [8] Dhiya Mahdi Asriny, Riyanto Jayadi , "Transfer Learning VGG16 for Classification Orange Fruit Images", *Journal of System and Management Sciences* Vol. 13 (2023) No. 1, pp. 206-217
- [9] Susanto, A., & Wibowo, E. (2021). "Deteksi Penyakit Daun Kopi Menggunakan CNN Berbasis VGG-16." *Jurnal Rekayasa Teknologi Informasi*, 5(2), 123-130.
- [10] Muhammad Syarief, et.al, "Convolutional neural network for maize leaf disease image classification", *TELKOMNIKA Telecommunication, Computing, Electronics and Control* Vol. 18, No. 3, June 2020, pp. 1376~1381
- [11] Nurhayati, S., & Hidayat, R. (2021). "Identifikasi Varietas Padi Berdasarkan Citra Daun Menggunakan Convolutional Neural Network." *Jurnal Teknologi Informasi dan Ilmu Komputer*, 8(4), 789-798
- [12] Simonyan, K., & Zisserman, A. (2014). "Very Deep Convolutional Networks for Large-Scale Image Recognition." *arXiv preprint arXiv:1409.1556*.
- [13] Lee, S. H., Chan, C. S., Wilkin, P., & Remagnino, P. (2017). "Deep-Plant: Plant Identification with Convolutional Neural Networks." *IEEE Transactions on Image Processing*, 26(12), 5927-5936.
- [14] Brown, M. J. (1997). "Durio – A Bibliographic Review." *Biotropica*, 29(2), 202-209.
- [15] Zhang, X., Zhang, Y., & Wang, Y. (2020). "Plant Leaf Classification Using Convolutional Neural Networks." *Computers and Electronics in Agriculture*, 169, 105178.