

## **Deteksi Jenis Tanaman Buah Tropis Indonesia Menggunakan Metode *Transfer Learning***

**Handrie Noprisson**

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia

*handrie.noprisson@dosen.undira.ac.id*

---

### **Article Info**

**Article history:**

Received, 2024-05-31

Revised, 2024-06-15

Accepted, 2024-06-29

---

**Kata Kunci:**

buah,  
VGG16,  
ResNet,  
MobileNet

---

### **ABSTRAK**

Penelitian yang diusulkan ini bertujuan untuk menentukan performa kinerja algoritma terbaik diantara VGG16, ResNet dan MobileNet dalam proses klasifikasi citra spesies tanaman buah. Berdasarkan hasil eksperimen penelitian, hasil klasifikasi citra tanaman buah terbaik yaitu hasil implementasi menggunakan ResNet. Akurasi ResNet pada tahap pelatihan, tahap evaluasi dan tahap pengujian masing-masing sebesar 94.65%, 89.28% dan 87.72%. Model VGG16 mendapatkan akurasi paling terendah, dengan hasil pada tahap pelatihan sebesar 3.36%, tahap validasi sebesar 3.36% dan tahap pengujian sebesar 3.33%. Rendahnya akurasi VGG16 dalam klasifikasi spesies datamanan buah dapat dikaitkan dengan beberapa faktor. Salah satu alasannya adalah penggunaan algoritma yang lemah dalam beberapa kasus, yang membatasi kemampuan model untuk secara akurat mengklasifikasikan buah. Selain itu, pelatihan pada sejumlah kecil dataset juga dapat berkontribusi pada akurasi yang lebih rendah, karena model mungkin tidak mempelajari pola dan variasi yang cukup beragam dalam penampilan buah.

---

### **ABSTRACT**

**Keywords:**

fruit,  
VGG16,  
ResNet,  
MobileNet

*This proposed research aims to determine the best algorithm performance among VGG16, ResNet and MobileNet in the process of image classification of fruit plant species. Based on the results of research experiments, the best fruit plant image classification results are the results of implementation using ResNet. The accuracy of ResNet in the training stage, evaluation stage and testing stage was 94.65%, 89.28% and 87.72% respectively. The VGG16 model obtained the lowest accuracy, with results at the training stage of 3.36%, the validation stage of 3.36% and the testing stage of 3.33%. The low accuracy of VGG16 in the classification of fruit species can be attributed to several factors. One reason is the use of weak algorithms in some cases, which limits the ability of models to accurately classify fruits. In addition, training on a small number of datasets can also contribute to lower accuracy, as models may not be able to achieve reliability.*

*This is an open access article under the [CC BY-SA](#) license.*



---

**Penulis Korespondensi:**

Handrie Noprisson,  
Fakultas Teknik dan Informatika,  
Universitas Dian Nusantara, Indonesia  
Email: [handrie.noprisson@dosen.undira.ac.id](mailto:handrie.noprisson@dosen.undira.ac.id)

---

## 1. PENDAHULUAN

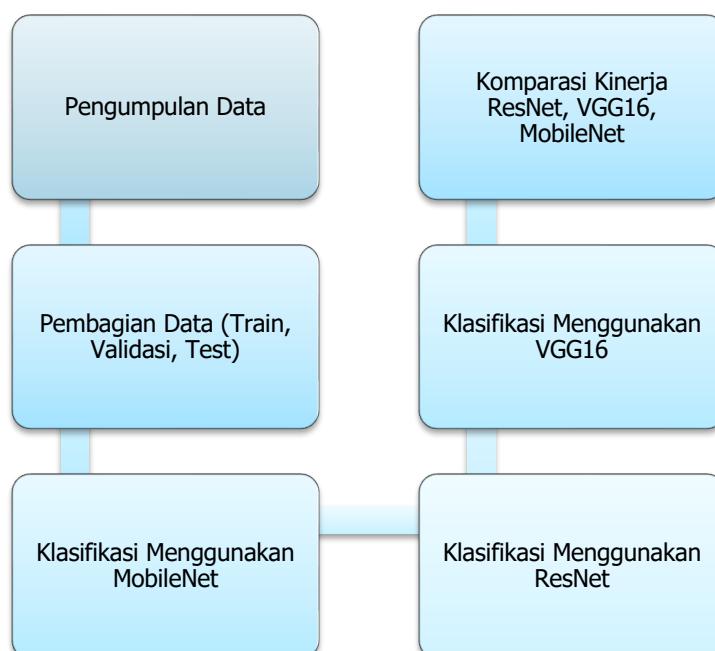
Buah-buahan merupakan asupan penting dari makanan manusia. Budidaya dan produksi buah telah menjadi bagian penting dari keseluruhan kegiatan pertanian. Dalam konteks agribisnis, masalah menarik terkait dengan realisasi deteksi dan klasifikasi buah yang tepat untuk mendukung proses pemilahan buah secara otomatis [1]–[6]. Beberapa aplikasi sistem klasifikasi dapat mendukung proses pembelian dengan mengidentifikasi jenis buah dengan nilai makanannya dan memberikan informasi dan saran terkait. Namun, masalah menjadi lebih relevan dalam konteks industri dalam melakukan otomatisasi kegiatan seperti mencocokkan varietas kualitas buah dengan informasi lain, misalnya, rincian gizi dan harga. Selain mengurangi tenaga kerja, biaya, dan bias yang terlibat dalam kuantifikasi manual, pemilahan otomatis juga berfungsi dengan baik untuk klasifikasi multi-kriteria dari jenis buah yang dianalisis [7]–[11].

Dalam beberapa tahun terakhir, teknologi kecerdasan buatan telah menyelesaikan banyak permasalahan [12]–[21]. Untuk mendeteksi jenis tanaman buah tropis Indonesia menggunakan metode transfer learning. Metode transfer learning untuk klasifikasi tanaman buah telah dieksplorasi di eksperimen di penelitian sebelumnya. Penelitian oleh Khullar (2022) menggunakan arsitektur transfer learning untuk eksperimen klasifikasi klasifikasi tanaman buah. Model transfer learning yang digunakan adalah model VGG16, InceptionV3, ResNet50, DenseNet, dan menemukan bahwa Inception memiliki akurasi terbaik [22]. Gulzar (2023) menggunakan arsitektur MobileNet untuk eksperimen klasifikasi klasifikasi tanaman buah. Arsitektur MobileNet mengungguli model lain seperti AlexNet, VGG16, InceptionV3, dan ResNet [2].

Berdasarkan studi pendahuluan, VGG16, ResNet dan MobileNet adalah model pembelajaran transfer yang paling perlu dieksplorasi lebih jauh untuk klasifikasi tanaman buah. Oleh karena itu, pada penelitian ini menggunakan VGG16, ResNet dan MobileNet melakukan klasifikasi dataset citra spesies tanaman buah. Hasil dari VGG16, ResNet dan MobileNet dievaluasi berdasarkan hasil kinerja algoritma terhadap dataset citra spesies tanaman buah. Penelitian yang diusulkan ini bertujuan untuk menentukan performa kinerja algoritma terbaik diantara VGG16, ResNet dan MobileNet dalam proses klasifikasi citra spesies tanaman buah.

## 2. METODE PENELITIAN

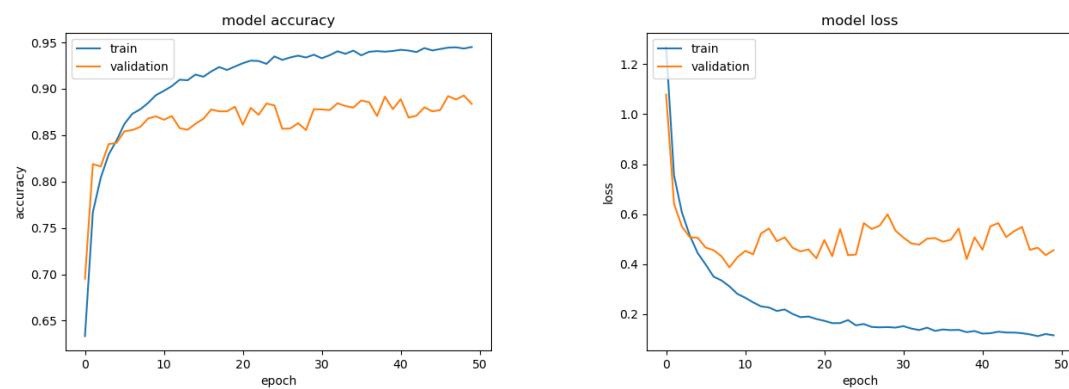
Dataset terdiri dari enam jenis buah yang biasa ditemukan di Indonesia: pisang, mangga, melon, jeruk, papaya dan semangka dan lainnya. Foto-foto tanggal ini diambil dengan smartphone dengan resolusi kamera ditetapkan pada 12 megapiksel ( $4032 \times 3024$ ) dan Google Images. Eksperimen penelitian akan menggunakan Python 3.0 pada sistem operasi Linux, dengan konfigurasi sistem menggunakan prosesor i7 dengan RAM 16 GB. Setiap kelas buah berisi antara 200 dan 240 citra. Citra buah ini dibagi menjadi dua subset dengan rasio 3: 1 atau 75% total data citra yang digunakan untuk melatih model, dan subset lainnya berisi 25% total data citra dari dataset yang digunakan untuk menguji model. Model algoritma yang digunakan adalah model transfer learning, antara lain VGG16, MobileNet, ResNet. Adapun tahap penelitian dapat dilihat pada **Gambar 1**.



Gambar 1 Tahap Penelitian

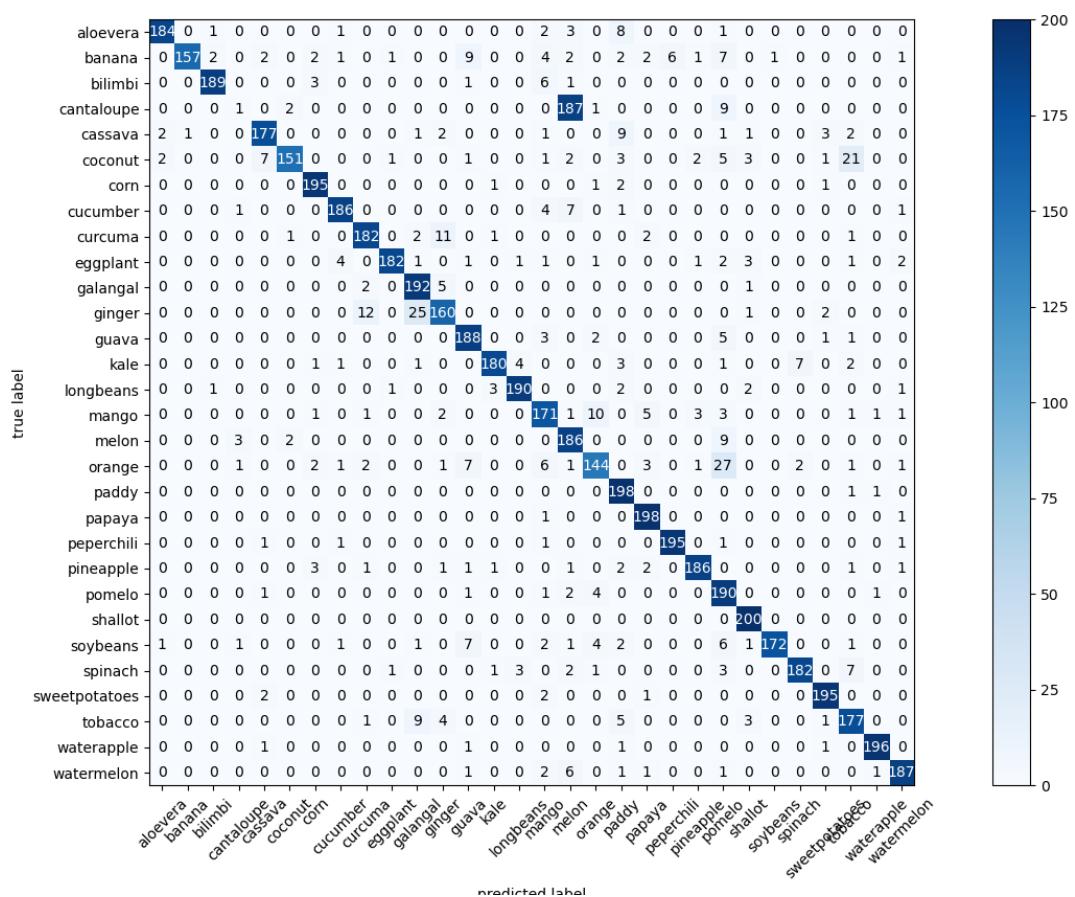
### 3. HASIL DAN ANALISIS

Pada tahap pelatihan dan tahap validasi dianalisis menggunakan model akurasi dan model loss. Grafik pada model akurasi dan model loss untuk tahap pelatihan dan tahap validasi didapatkan setelah proses iterasi atau epoch yang didefinisikan yaitu 50 epoch selesai dijalankan. Grafik model akurasi dan model loss memiliki sumbu X yang menunjukkan jumlah epoch pada tahap pelatihan atau tahap validasi sedangkan n sumbu Y merupakan nilai akurasi atau loss dengan nilai antara 0 sampai 1. Hasil grafik model akurasi dan model loss untuk model MobileNet dapat dilihat pada **Gambar 2**.



Gambar 2 Grafik Akurasi dan Loss MobileNet

Selanjutnya untuk mengevaluasi model MobileNet, hasil untuk tahap pengujian dianalisis melalui nilai confusion matrix. Model ini digunakan untuk mengukur kinerja metode MobileNet dalam mengetahui seberapa banyak prediksi dengan benar dan salah dari total keseluruhan data citra tanaman buah yang ada pada dataset pengujian. Hasil confusion matriks untuk metode MobileNet dapat dilihat pada **Gambar 3**.



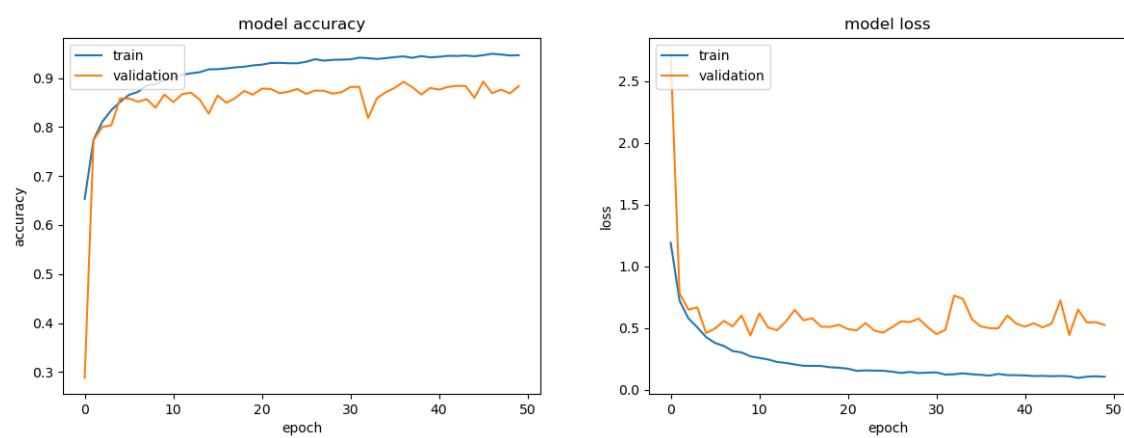
Gambar 3 Confusion Matrix MobileNet

Selain model confusion matrix untuk mengevaluasi keberhasilan model MobileNet, perhitungan precision, recall, dan f1-score untuk setiap kelas spesies tanaman buah juga dianalisis. Berdasarkan nilai TP, TN, FP, dan FN yang ada confusion matrix untuk masing-masing kelas tanaman buah, dihitung precision, recall, dan f1-score dengan menggunakan rumus masing-masing. Hasil dari perhitungan precision, recall, dan f1-score untuk semua kelas spesies tanaman buah dapat dilihat pada **Tabel 1**.

Tabel 1 Precision, Recall, F1-Score dari ResNet

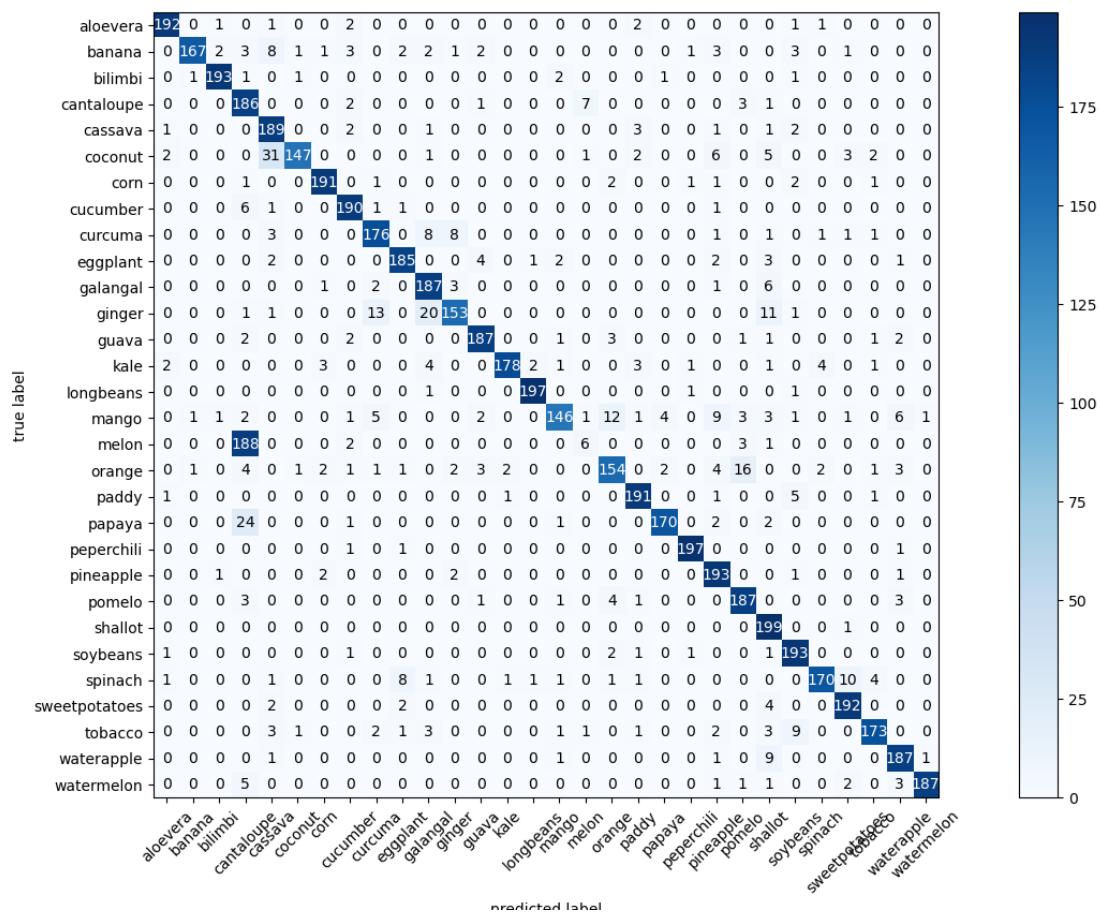
	precision	recall	f1-score	support
aloevera	0.97	0.92	0.95	200
banana	0.99	0.79	0.88	200
bilimbi	0.98	0.94	0.96	200
cantaloupe	0.14	0.01	0.01	200
cassava	0.93	0.89	0.91	200
coconut	0.97	0.76	0.85	200
corn	0.94	0.97	0.96	200
cucumber	0.95	0.93	0.94	200
curcuma	0.91	0.91	0.91	200
eggplant	0.98	0.91	0.94	200
galangal	0.83	0.96	0.89	200
ginger	0.86	0.80	0.83	200
guava	0.86	0.94	0.90	200
kale	0.96	0.90	0.93	200
longbeans	0.96	0.95	0.95	200
mango	0.82	0.85	0.84	200
melon	0.46	0.93	0.62	200
orange	0.86	0.72	0.78	200
paddy	0.83	0.99	0.90	200
papaya	0.93	0.99	0.96	200
peperchili	0.97	0.97	0.97	200
pineapple	0.96	0.93	0.94	200
pomelo	0.70	0.95	0.81	200
shallot	0.93	1.00	0.96	200
soybeans	0.99	0.86	0.92	200
spinach	0.95	0.91	0.93	200
sweetpotatoes	0.95	0.97	0.96	200
tobacco	0.82	0.89	0.85	200
waterapple	0.98	0.98	0.98	200
watermelon	0.95	0.94	0.94	200
accuracy			0.88	6000
macro avg	0.88	0.88	0.87	6000
weighted avg	0.88	0.88	0.87	6000

Pada tahap pelatihan dan tahap validasi dianalisis menggunakan model akurasi dan model loss. Grafik pada model akurasi dan model loss untuk tahap pelatihan dan tahap validasi didapatkan setelah proses iterasi atau epoch yang didefinisikan yaitu 50 epoch selesai dijalankan. Grafik model akurasi dan model loss memimiki sumbu X yang menunjukkan jumlah epoch pada tahap pelatihan atau tahap validasi sedangkan n sumbu Y merupakan nilai akurasi atau loss dengan nilai antara 0 sampai 1. Hasil grafik model akurasi dan model loss untuk model ResNet dapat dilihat pada **Gambar 4**.



Gambar 4 Grafik Akurasi dan Loss ResNet

Selanjutnya untuk mengevaluasi model ResNet, hasil untuk tahap pengujian dianalisis melalui nilai confusion matrix. Model ini digunakan untuk mengukur kinerja metode ResNet dalam mengetahui seberapa banyak prediksi dengan benar dan salah dari total keseluruhan data citra tanaman buah yang ada pada dataset pengujian. Hasil confusion matriks untuk metode ResNet dapat dilihat pada **Gambar 5**.



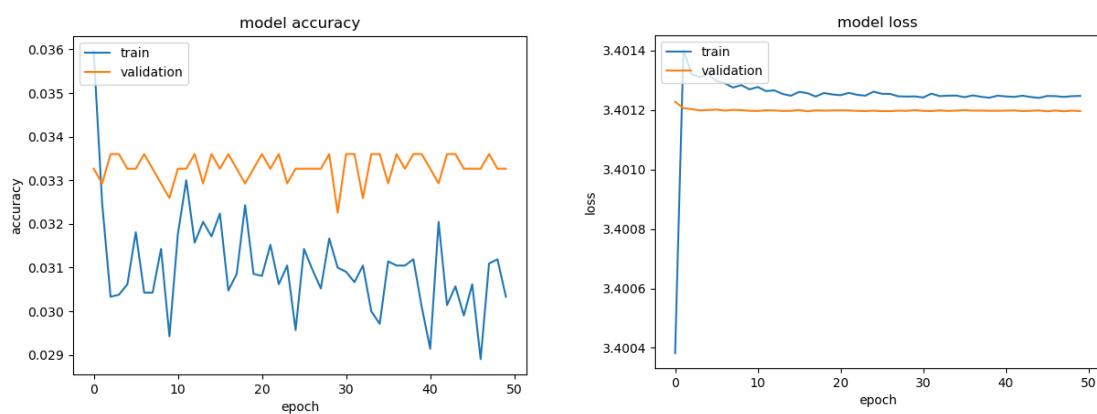
Gambar 5 Confusion Matrix ResNet

Selain model confusion matrix untuk mengevaluasi keberhasilan model ResNet, perhitungan precision, recall, dan f1-score untuk setiap kelas spesies tanaman buah juga dianalisis. Berdasarkan nilai TP, TN, FP, dan FN yang ada pada confusion matrix untuk masing-masing kelas tanaman buah, dihitung precision, recall, dan f1-score dengan menggunakan rumus masing-masing. Hasil dari perhitungan precision, recall, dan f1-score untuk semua kelas spesies tanaman buah dapat dilihat pada **Tabel 2**

Tabel 2 Precision, Recall, F1-Score dari MobileNet

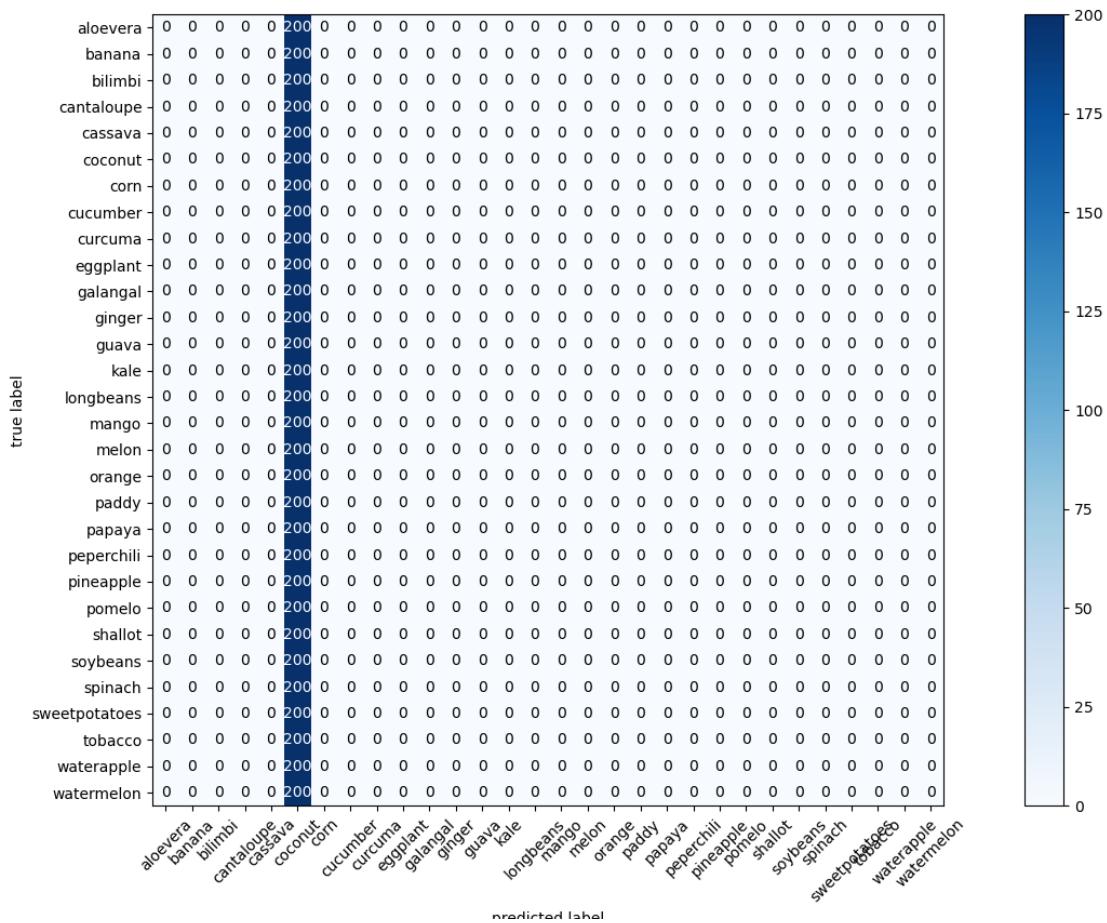
	precision	recall	f1-score	support
aloevera	0.96	0.96	0.96	200
banana	0.98	0.83	0.90	200
bilimbi	0.97	0.96	0.97	200
cantaloupe	0.44	0.93	0.59	200
cassava	0.78	0.94	0.85	200
coconut	0.97	0.73	0.84	200
corn	0.95	0.95	0.95	200
cucumber	0.91	0.95	0.93	200
curcuma	0.88	0.88	0.88	200
eggplant	0.92	0.93	0.92	200
galangal	0.82	0.94	0.87	200
ginger	0.91	0.77	0.83	200
guava	0.94	0.94	0.94	200
kale	0.98	0.89	0.93	200
longbeans	0.98	0.98	0.98	200
mango	0.93	0.73	0.82	200
melon	0.38	0.03	0.06	200
orange	0.87	0.77	0.81	200
paddy	0.93	0.95	0.94	200
papaya	0.96	0.85	0.90	200
peperchili	0.98	0.98	0.98	200
pineapple	0.84	0.96	0.90	200
pomelo	0.87	0.94	0.90	200
shallot	0.79	0.99	0.88	200
soybeans	0.88	0.96	0.92	200
spinach	0.96	0.85	0.90	200
sweetpotatoes	0.91	0.96	0.93	200
tobacco	0.94	0.86	0.90	200
waterapple	0.90	0.94	0.92	200
watermelon	0.99	0.94	0.96	200
accuracy			0.88	6000
macro avg	0.88	0.88	0.87	6000
weighted avg	0.88	0.88	0.87	6000

Pada tahap pelatihan dan tahap validasi dianalisis menggunakan model akurasi dan model loss. Grafik pada model akurasi dan model loss untuk tahap pelatihan dan tahap validasi didapatkan setelah proses iterasi atau epoch yang didefinisikan yaitu 50 epoch selesai dijalankan. Grafik model akurasi dan model loss memimiki sumbu X yang menunjukkan jumlah epoch pada tahap pelatihan atau tahap validasi sedangkan n sumbu Y merupakan nilai akurasi atau loss dengan nilai antara 0 sampai 1. Hasil grafik model akurasi dan model loss untuk model VGG16 dapat dilihat pada **Gambar 6**.



Gambar 6 Grafik Akurasi dan Loss VGG16

Selanjutnya untuk mengevaluasi model MobileNet, hasil untuk tahap pengujian dianalisis melalui nilai confusion matrix. Model ini digunakan untuk mengukur kinerja metode VGG16 dalam mengetahui seberapa banyak prediksi dengan benar dan salah dari total keseluruhan data citra tanaman buah yang ada pada dataset pengujian. Hasil confusion matriks untuk metode VGG16 dapat dilihat pada **Gambar 7**.



Gambar 7 Confusion Matrix VGG16

Selain model confusion matrix untuk mengevaluasi keberhasilan model VGG16, perhitungan precision, recall, dan f1-score untuk setiap kelas spesies tanaman buah juga dianalisis. Berdasarkan nilai TP, TN, FP, dan FN yang ada confusion matrix untuk masing-masing kelas tanaman buah, dihitung precision, recall, dan f1-score dengan menggunakan rumus masing-masing. Hasil dari perhitungan precision, recall, dan f1-score untuk semua kelas spesies tanaman buah dapat dilihat pada **Tabel 3**.

Tabel 3 *Precision, Recall, F1-Score dari VGG16*

	precision	recall	f1-score	support
aloe vera	0.00	0.00	0.00	200
banana	0.00	0.00	0.00	200
bilimbi	0.00	0.00	0.00	200
cantaloupe	0.00	0.00	0.00	200
cassava	0.00	0.00	0.00	200
coconut	0.03	1.00	0.06	200
corn	0.00	0.00	0.00	200
cucumber	0.00	0.00	0.00	200
curcuma	0.00	0.00	0.00	200
eggplant	0.00	0.00	0.00	200
galangal	0.00	0.00	0.00	200
ginger	0.00	0.00	0.00	200
guava	0.00	0.00	0.00	200
kale	0.00	0.00	0.00	200
longbeans	0.00	0.00	0.00	200
mango	0.00	0.00	0.00	200
melon	0.00	0.00	0.00	200
orange	0.00	0.00	0.00	200
paddy	0.00	0.00	0.00	200
papaya	0.00	0.00	0.00	200
peperchili	0.00	0.00	0.00	200
pineapple	0.00	0.00	0.00	200
pomelo	0.00	0.00	0.00	200
shallot	0.00	0.00	0.00	200
soybeans	0.00	0.00	0.00	200
spinach	0.00	0.00	0.00	200
sweetpotatoes	0.00	0.00	0.00	200
tobacco	0.00	0.00	0.00	200
waterapple	0.00	0.00	0.00	200
watermelon	0.00	0.00	0.00	200
accuracy			0.03	6000
macro avg	0.00	0.03	0.00	6000
weighted avg	0.00	0.03	0.00	6000

Berdasarkan hasil eksperimen penelitian, hasil klasifikasi citra tanaman buah terbaik yaitu hasil implementasi menggunakan ResNet. Akurasi ResNet pada tahap pelatihan, tahap evaluasi dan tahap pengujian masing-masing sebesar 94.65%, 89.28% dan 87.72%. Model VGG16 mendapatkan akurasi paling terendah, dengan hasil pada tahap pelatihan sebesar 3.36%, tahap validasi sebesar 3.36% dan tahap pengujian sebesar 3.33%. Adapun hasil dari eksperimen dari penelitian ini dapat dilihat pada **Tabel 4**.

Tabel 4 Perbandingan Model Transfer Learning

Model	Train Acc	Val Acc	Test Acc
1. MobileNet	94.34%	89.28%	88.18%
2. ResNet	94.65%	89.28%	87.72%
3. VGG16	3.36%	3.36%	3.33%

#### 4. KESIMPULAN

Berdasarkan hasil eksperimen penelitian, hasil klasifikasi citra tanaman buah terbaik yaitu hasil implementasi menggunakan ResNet. Akurasi ResNet pada tahap pelatihan, tahap evaluasi dan tahap pengujian masing-masing sebesar 94.65%, 89.28% dan 87.72%. Model VGG16 mendapatkan akurasi paling terendah, dengan hasil pada tahap pelatihan sebesar 3.36%, tahap validasi sebesar 3.36% dan tahap pengujian sebesar 3.33%. Rendahnya akurasi VGG16 dalam klasifikasi spesies datnaman buah dapat dikaitkan dengan beberapa faktor. Salah satu alasannya adalah penggunaan algoritma yang lemah dalam beberapa kasus, yang membatasi kemampuan model untuk secara akurat mengklasifikasikan buah. Selain itu, pelatihan pada sejumlah kecil dataset juga dapat berkontribusi pada akurasi yang lebih rendah, karena model mungkin tidak mempelajari pola

dan variasi yang cukup beragam dalam penampilan buah. Faktor lain adalah adanya kesamaan visual antara jenis buah yang berbeda dan variasi dalam spesies buah yang sama, sehingga sulit bagi model untuk membedakan antara mereka secara akurat. Selain itu, masalah overfitting juga dapat memengaruhi akurasi, karena model mungkin menjadi terlalu khusus untuk data pelatihan dan berjuang untuk menggeneralisasi ke sampel buah baru yang tidak terlihat [23], [24].

## UCAPAN TERIMA KASIH

Terima kasih kepada Universitas Dian Nusantara yang telah mendanai penelitian ini melalui skema penelitian internal dengan No. Kontak: 11/78/H-SPK/II/2024.

## REFERENSI

- [1] V. Ashok and D. S. Vinod, “A Novel Fusion of Deep Learning and Android Application for Real-Time Mango Fruits Disease Detection,” pp. 781–791, 2021.
- [2] Y. Gulzar, “Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique,” *Sustainability*, vol. 15, no. 3, p. 1906, 2023.
- [3] T. B. Shahi, C. Sitaula, A. Neupane, and W. Guo, “Fruit classification using attention-based MobileNetV2 for industrial applications,” *PLoS One*, vol. 17, no. 2, p. e0264586, 2022.
- [4] D. Hussain, I. Hussain, M. Ismail, A. Alabrah, S. S. Ullah, and H. M. Alaghbari, “A simple and efficient deep learning-based framework for automatic fruit recognition,” *Comput. Intell. Neurosci.*, vol. 2022, 2022.
- [5] S. D. Asri, D. Ramayanti, A. D. Putra, and Y. T. Utami, “Deteksi Roda Kendaraan Dengan Circle Hough Transform (CHT) dan Support Vector Machine (SVM),” *J. Teknoinfo*, vol. 16, no. 2, pp. 427–434, 2022.
- [6] S. D. Asri, I. Jaya, A. Buono, and S. H. Wijaya, “Fish Detection in Seagrass Ecosystem using Masked-Otsu in HSV Color Space,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 12, 2022.
- [7] C. C. Ukwuoma, Q. Zhiguang, M. B. Bin Heyat, L. Ali, Z. Almaspoor, and H. N. Monday, “Recent advancements in fruit detection and classification using deep learning techniques,” *Math. Probl. Eng.*, vol. 2022, pp. 1–29, 2022.
- [8] G. Xue, S. Liu, and Y. Ma, “A hybrid deep learning-based fruit classification using attention model and convolution autoencoder,” *Complex Intell. Syst.*, pp. 1–11, 2020.
- [9] K. Albarak, Y. Gulzar, Y. Hamid, A. Mehmood, and A. B. Soomro, “A deep learning-based model for date fruit classification,” *Sustainability*, vol. 14, no. 10, p. 6339, 2022.
- [10] N. Saranya, K. Srinivasan, S. K. Pravin Kumar, V. Rukkumani, and R. Ramya, “Fruit classification using traditional machine learning and deep learning approach,” in *Computational Vision and Bio-Inspired Computing: ICCVBIC 2019*, 2020, pp. 79–89.
- [11] N. Mamat, M. F. Othman, R. Abdulghafar, A. A. Alwan, and Y. Gulzar, “Enhancing image annotation technique of fruit classification using a deep learning approach,” *Sustainability*, vol. 15, no. 2, p. 901, 2023.
- [12] U. Rusmawan and I. Mulya, “Sistem Informasi Koperasi Menggunakan Metode Rapid Application Development (RAD),” *J. Inf. Syst. Technol.*, vol. 1, no. 1, pp. 1–10, 2022.
- [13] G. Purnama and D. Ramayanti, “Aplikasi ChatBot Sistem Parental Control berbasis IoT,” *Arcitech J. Comput. Sci. Artif. Intell.*, vol. 1, no. 2, pp. 127–138, 2021.
- [14] D. Ramayanti, Y. Jumaryadi, D. M. Gufron, and D. D. Ramadha, “Sistem Keamanan Perumahan Menggunakan Face Recognition,” *TIN Terap. Inform. Nusant.*, vol. 3, no. 12, pp. 486–496, 2023.
- [15] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, “Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification,” *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [16] V. Ayumi, “Performance Evaluation of Support Vector Machine Algorithm for Human Gesture Recognition,” *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 6, pp. 204–210, 2020.
- [17] A. Ratnasari, Y. Jumaryadi, and G. Gata, “Sistem Pakar Deteksi Penyakit Ginekologi Menggunakan Metode Forward Chaining,” *Resolusi Rekayasa Tek. Inform. dan Inf.*, vol. 3, no. 5, pp. 321–327, 2023.
- [18] B. Y. Geni, A. Supriyadi, H. Khotimah, and W. I. Yanti, “Rancang Bangun Company Profile Berbasis Web Menggunakan Metode Waterfall (Studi Kasus: APM Frozen Food),” *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 6, no. 1, pp. 75–85, 2024.
- [19] B. Yuliadi and A. Nugroho, “Integration between management capability and relationship capability to boost supply chain project performance,” *Int. J. Supply Chain Manag.*, vol. 8, no. 2, pp. 241–252, 2019.
- [20] S. Hesti, “The effects of relational social capital and technological factors on knowledge sharing in an online community,” *Int. J. Innov. Creat. Chang.*, vol. 13, no. 4, 2020.
- [21] I. Kamil, M. Ariani, and I. A. Irawan, “The influence of lifestyle and financial literacy on online paylater

- system and its impact on spending behavior," *J. Econ. Bus. Lett.*, vol. 4, no. 2, pp. 51–62, 2024.
- [22] V. Khullar, R. Gaurang Tiwari, A. Kumar Agarwal, and A. Misra, "Investigating Efficacy of Transfer Learning for Fruit Classification," in *Machine Intelligence and Data Science Applications: Proceedings of MIDAS 2021*, Springer, 2022, pp. 419–426.
- [23] J. A. Campos-Leal, A. Yee-Rendón, and I. F. Vega-Lopez, "Simplifying VGG-16 for Plant Species Identification," *IEEE Lat. Am. Trans.*, vol. 20, pp. 2330–2338, 2022.
- [24] J. Pardede, B. Sitohang, S. Akbar, and M. L. Khodra, "Implementation of Transfer Learning Using VGG16 on Fruit Ripeness Detection," *Int. J. Intell. Syst. Appl.*, vol. 13, no. 2, pp. 52–61, 2021.