

Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan Metode *Deep Learning*

Ditra Liandaputra^{1✉}, Amalia Zahra²

^{1,2} Department of Computer Science, BINUS Graduate Program, Master of Computer Science, Bina Nusantara University, Jakarta, Indonesia

Informasi Artikel

Riwayat Artikel

Diserahkan : 19-03-2024

Direvisi : 28-03-2024

Diterima : 30-03-2024

Kata Kunci:

Deep Learning, CNN, klasifikasi

Keywords :

Deep Learning, CNN, Classification.

ABSTRAK

Penerapan perlakuan pascapanen dan manajemen bangsal hortikultura yang baik meningkatkan hasil dan mutu produk, mendukung daya saing hortikultura. Namun, penentuan kematangan buah nanas masih menggunakan metode tradisional, tidak konsisten, berpotensi merugikan finansial. Pemilihan dan klasifikasi buah nanas sesuai indeks kematangan standar dapat mengurangi kerusakan hasil dan mempertahankan mutu, mendukung kebutuhan pasar lokal dan internasional. Penelitian klasifikasi kematangan nanas berfokus pada *deep learning*, menggunakan data perkebunan rakyat, dan memusatkan pada badan nanas tanpa mahkota dalam 4 kelas kematangan. Model klasifikasi MobileNetV2 dengan augmentasi geometrik dan fotometrik mencapai akurasi 93%, dibandingkan dengan AlexNet dan VGG16. Hasil penelitian diharapkan meningkatkan efisiensi pertanian, membantu petani, dan memberi wawasan pada deteksi dan klasifikasi kematangan nanas untuk pasar lokal dan internasional. Eksperimen evaluasi memberikan pemahaman kinerja model dalam mendeteksi dan mengklasifikasikan kematangan buah nanas.

ABSTRACT

The implementation of post-harvest treatments and good horticultural shed management enhances the yield and quality of products, supporting horticultural competitiveness. However, determining the maturity of pineapple fruits still relies on traditional methods, lacks consistency, and has the potential to cause financial losses. Selecting and classifying pineapples according to standard maturity indices can reduce yield losses and maintain quality, meeting the needs of local and international markets. Research on pineapple maturity classification focuses on deep learning, utilizing data from smallholder farms, and specifically targeting the pineapple body without the crown in 4 maturity classes. The MobileNetV2 classification model with geometric and photometric augmentation achieves 93% accuracy, compared to AlexNet and VGG16. The research aims to improve agricultural efficiency, assist farmers, and provide insights into pineapple maturity detection and classification for local and international markets. Evaluation experiments provide an understanding of the model's performance in detecting and classifying pineapple fruit maturity.

Corresponding Author :

Ditra liandaputra

Department of Computer Science, BINUS Graduate Program, Master of Computer Science, Bina Nusantara University

Anggrek Campus, Jl. Kebon Jeruk Raya No. 27, Jakarta Barat, 11530 Indonesia

Email : ditra.liandaputra@binus.ac.id

PENDAHULUAN

Menurut data dari Badan Pusat Statistik (BPS), ekspor buah hortikultura telah mengalami peningkatan yang cukup signifikan selama empat tahun terakhir (BPS, 2022). Dalam kategori hortikultura, buah nanas memiliki pangsa ekspor yang lebih besar, mencapai 41,36% dari total nilai ekspor produk hortikultura yang mencapai 84,48%. Hongkong menjadi negara tujuan ekspor nanas Indonesia yang paling tinggi dengan persentase sebesar 24,4%, diikuti oleh Korea dengan 15,8%. Pada tahun 2020, nilai ekspor nanas Indonesia mencapai US\$ 274.126 juta, mengalami peningkatan sebesar 34,49% dibandingkan dengan tahun sebelumnya yang hanya US\$ 203,819 juta (sumber: BPS, 2021), hal ini sejalan dengan peningkatan produksi nanas di Indonesia selama 5 tahun terakhir, seperti yang terlihat dalam tabel 1.1. Khususnya di Provinsi Bangka Belitung, buah nanas menjadi salah satu primadona dan komoditas dengan produksi yang tinggi. Salah satu varietas nanas yang sangat terkenal dari provinsi tersebut adalah nanas tuatunu yang memiliki rasa yang manis, ukuran yang besar, dan mayoritas ditanam oleh petani di Kota Pangkalpinang.

Tabel 1 Produksi nanas di Indonesia

Tahun Produksi	Produksi per ton
2022	3.203.775
2021	2.886.417
2020	2.447.243
2019	2.196.458
2018	1.805.506

(Sumber: BPS,2022)

Peneliti dari Pusat Kajian Hortikultura Tropika IPB mengindikasikan bahwa standar ekspor nanas secara global mengacu pada varietas nanas MD2 dan nanas MA2 (Amar et al, 2015). Varian ini dapat dikenali dengan mudah melalui perubahan warna dari hijau ke kuning di bagian luar buah, warna kuning cerah di bagian dalamnya, dan memiliki kadar gula sekitar 14-18%, serta kadar asam sekitar 1,65-2,14% (agrofarm.co.id). Nanas MD2 adalah salah satu varietas termanis di dunia dan secara alami mengandung sekitar empat kali jumlah vitamin C dibandingkan dengan kultivar lainnya. Mudah dikenali dari kulit emasnya yang cerah, nanas MD2 juga dihargai karena keseragaman dan konsistensi ukurannya. Dalam memenuhi konsumsi pasar lokal dan ekspor, pemerintah telah mengeluarkan Permentan No. 73 tahun 2013 tentang Pedoman Panen, Pascapanen dan Pengelolaan Bangsa Hortikultura yang baik agar meningkatkan hasil dan kesegaran mutu sehingga dapat meningkatkan daya saing produk hortikultura. Akan tetapi, dalam menentukan tingkat kematangan buah nanas masih dilakukan dengan cara tradisional yaitu berdasarkan penglihatan mata manusia seperti melihat warna, tekstur kulit, perabaan fisik buah, serta umur tanaman. Tindakan semacam itu berpotensi menyebabkan kerugian finansial karena kurangnya ketepatan dan konsistensi. Namun, dengan memilih dan mengelompokkan buah nanas sesuai dengan standar tingkat kematangan yang ditetapkan, dapat membantu dalam penanganan pasca panen nanas untuk mengurangi kerusakan hasil, menjaga kualitas, serta memperpanjang masa simpan produk agar sesuai dengan persyaratan pasar lokal maupun internasional.


Para peneliti di bidang pertanian telah secara bertahap mengadopsi metode pembelajaran mendalam untuk meningkatkan aplikasi teknologi. Dalam upaya mencapai kinerja deteksi yang lebih baik, para peneliti terus melakukan berbagai perbaikan pada model pembelajaran mendalam. Beberapa perbaikan mencakup modifikasi struktur jaringan, penambahan modul fungsional ke dalam model, dan optimalisasi metode pemrosesan pasca-model. Dengan demikian, model pembelajaran mendalam semakin mampu mengenali dan mendeteksi dengan akurasi tinggi berbagai aspek penting dalam pertanian, seperti identifikasi buah, penyakit hingga tingkat kematangan buah. Beberapa peneliti yang berfokus pada identifikasi dan klasifikasi penyakit buah (Nasir et al., 2020) menggunakan arsitektur VGG19 sebagai model dasar yang diklaim mendapatkan akurasi sebesar 99% dalam mengklasifikasi penyakit buah. Selain itu pengklasifikasian terhadap 40 macam buah yang telah dilakukan menggunakan arsitektur dasar mobilenetV2 dengan *transfer leaning* mendapatkan akurasi sebesar 99% dengan memodifikasi *top*

layer dengan menambahkan 5 layers (Gulzar, 2023). Dalam penelitian lain (Assuncao et al., 2020), mengusulkan model *deep learning* dengan menggabungkan beberapa teknik *preprocessing* yang dapat beroperasi diperangkat selular, yang bertujuan untuk mengklasifikasikan buah persik berdasarkan tingkat kesegarannya serta mampu mengidentifikasi tiga jenis penyakit yang ditemukan pada buah persik dengan akurasi 96%. Penerapan *deep learning* pada robot untuk pemanenan buah juga dilakukan oleh (Altaheri et al., 2019), yang mendapatkan akurasi model sebesar 99,01%. Penelitian tentang identifikasi tingkat kematangan buah dengan menggunakan teknologi computer vision dan deep learning telah semakin berkembang pesat di bidang pertanian. Para peneliti berusaha untuk menghadirkan solusi yang akurat dan efisien bagi para petani dan industri pertanian. Untuk mencapai tujuan tersebut, penelitian secara berkelanjutan mengkaji dan menerapkan berbagai metode dan teknik dalam pembelajaran mendalam. Seperti penelitian pada buah pisang (Saranya et al., 2022) yang memprediksi kondisi buah dan warna, menggunakan arsitektur *Convolutional Neural Network* (CNN) antara lain VGG16 dan ResNet50 mendapatkan akurasi sebesar 99,12% dan 82,20%. Penerapan arsitektur model yang lain selain itu, (Pardede et al., 2021) penerapan arsitektur model VGG16 dalam mengukur tingkat kematangan buah tomat mendapatkan akurasi 84% pada model dasar. Beberapa percobaan telah dilakukan (Miraei Ashtiani et al., 2021) untuk membandingkan arsitektur CNN seperti DenseNet, Inception-V3, ResNet-18, ResNet-50, dan AlexNet dalam menentukan tingkat kematangan buah mulberry. Dengan menerapkan metode transfer learning yang telah di fine tuning, hasil terbaik diperoleh dengan tingkat akurasi mencapai 98,32% menggunakan AlexNet dan 98,65% menggunakan ResNet-18. Zhang (Zhang et al., 2021) menghadirkan sebuah metode deteksi nanas berbasis SSD dengan menggunakan MobileNet sebagai *backbone* untuk meningkatkan kecepatan deteksi. Namun, model ini memiliki batasan karena hanya dapat mendeteksi satu jenis nanas yang sudah matang dan tidak mampu membedakan tingkat kematangan yang berbeda pada nanas tersebut. (Yang et al., 2023)

Berdasarkan dari hasil penelitian sebelumnya (Abu Bakar et al., 2013; Lustini, 2019; Viana et al., 2020; Edwin R. A. et al., 2021; Wang & Chai, 2022) diketahui bahwa tingkat kematangan buah nanas yang diteliti hanya sebatas tingkat kematangan untuk 3 kelas saja yakni: mentah, matang, sangat matang. Kemudian penelitian (Kanjana Wattana et al., 2023) melakukan klasifikasi terhadap 4 kelas tingkat kemanisan buah nanas berdasarkan data gambar menggunakan alexnet. Selain itu penelitian (Al Buhaisi, 2021) mengklasifikasi jenis nanas dan nanas mini berdasarkan data foto. Dalam penelitian ini akan mengelompokkan tingkat kematangan menjadi 4 kelas yaitu mentah, kurang matang, matang, dan terlalu matang yang berfokus pada buah badan buah nanas tanpa mahkota kemudian metode *deep learning* dengan menggunakan beberapa arsitektur CNN sebagai model untuk mengklasifikasi tingkat kematangan buah nanas. Penelitian ini menggunakan *Dataset* buah nanas varietas Tuatunu yang dikumpulkan secara mandiri oleh peneliti yang akan diambil langsung dari perkebunan rakyat. Harapannya, hasil dari penelitian ini dapat memberikan sumbangan positif dalam meningkatkan efisiensi produksi pertanian serta memberikan bantuan kepada petani dalam mengelola hasil panen secara lebih optimal.

METODE PENELITIAN

Dalam penelitian ini, terdapat beberapa tahapan yang meliputi perumusan masalah serta studi literatur terhadap penelitian yang telah dilakukan sebelumnya, mengumpulkan data gambar nanas, melakukan *pre-processing* data, mengembangkan model CNN antara lain MobileNetV1, MobilnetV2, VGG16 dan AlexNet.



Gambar 1. Tahapan Penelitian

Langkah awal dari penelitian ini adalah melakukan identifikasi dan perumusan masalah yang terkait dengan penentuan tingkat kematangan buah nanas. Dimana penentuan Tingkat kematangan ini berpengaruh pada pengolahan pascapanen yang sangat berpengaruh pada kualitas buah nanas pada saat proses pengiriman hingga ke pasar atau tempat pengolahan selanjutnya. Cara yang dilakukan pada penentuan Tingkat kematangan buah nanas ini masih dilakukan secara manual sehingga penentuan ini sering terjadi kesalahan dalam pemilihan buah nanas yang menyebabkan kerugian finansial dikarenakan kualitas buah menjadi menurun yang berpengaruh pada harga jual. Berdasarkan studi literatur terdahulu, pendekatan terbaik pada proses pemilihan buah nanas ini dilakukan menggunakan metode deep learning, yang mana hasil yang diberikan sangat baik dalam mengklasifikasikan Tingkat kematangan buah. Kemudian dilakukan pengambilan gambar dari perkebunan rakyat menggunakan smartphone dengan kondisi 1 buah nanas per foto. *Dataset* dikumpulkan dan diambil dari perkebunan rakyat secara mandiri menggunakan kamera utama *smartphone Oppo A95* dengan resolusi 48 Megapixel. *Dataset* di ambil diperkebunan rakyat dengan 4 lokasi yang bertempat di desa Tua Tunu kota Pangkalpinang provinsi Bangka Belitung. Proses pengambilan gambar dilakukan pada siang hingga sore hari, mulai dari pukul 13:00 hingga 18:00 WIB, untuk mencakup berbagai kondisi cahaya yang ada dalam situasi nyata. Fokus objek utama dalam pengambilan gambar adalah satu buah nanas. Kategori yang diambil dalam foto ini adalah mentah, kurang matang, matang dan terlalu matang dengan pelabelan tingkat kematangan dibantu oleh 1 orang petani nanas dengan jumlah foto sebanyak 400 gambar dengan masing-masing kategori sebanyak 100 gambar. Selanjutnya gambar dilakukan *preprocessing* data, dalam tahap ini dilakukan anotasi atau pelabelan menggunakan *vgganotator* yang dibantu oleh 1 orang petani nanas yang merupakan pemilik kebun nanas. Selanjutnya dilakukan *cropping* gambar dan *resize* menjadi 224x224x3 dikarenakan *input proses* data hanya menerima gambar dengan ukuran ini. Gambar yang dihasilkan dari proses ini hanya berfokus pada badan buah nanas. Selanjutnya dilakukan augmentasi data dengan tipe geometrik dan fotometrik serta tipe augmentasi kombinasi yang terdiri dari gambar asli, geometrik dan fotometrik yang mana dalam pengujian tipe augmentasi ini akan menjadi penentu penggunaan tipe augmentasi pada arsitektur model selanjutnya. Setelah dievaluasi akan dilakukan

perbandingan arsitektur AlexNet (Kanjawattana et al., 2023), VGG16 (Pardede et al., 2021; Al Buhaisi, 2021), MobilenetV2 (Gulzar, 2023) serta membandingkan arsitektur yang diusulkan peneliti sehingga didapatkan arsitektur terbaik dengan tipe augmentasi terbaik. Pada tahapan evaluasi model, akan dilakukan pengujian dengan *test* yang akan menghasilkan *recall*, *precision*, *f1-score* dan mengukur akurasi dari setiap arsitektur yang diuji dengan rumus sebagai berikut:

1. Confusion Matrix

Confusion matrix adalah metode yang digunakan untuk mengevaluasi performa model klasifikasi. Berikut ini adalah gambar representasi dari *confusion matrix*:

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2 Confusion matrix

Berdasarkan gambar diatas, penjelasan terkait *confusion matrix*, antara lain :

- TP (*True Positive*) adalah jumlah data yang kelas aktualnya adalah positif dan prediksinya juga positif.
- FN (*False Negative*) adalah total data yang kelas aktualnya adalah positif namun prediksinya negatif.
- FP (*False Positive*) adalah jumlah data yang kelas aktualnya adalah negatif tetapi diprediksi sebagai positif.
- TN (*True Negative*) adalah jumlah data yang kelas aktualnya adalah negatif dan prediksinya juga negatif.

2. Presisi

Presisi merupakan fungsi model yang hanya mengidentifikasi objek terkait. Presisi merupakan presentase prediksi positif yang benar yang di rumuskan sebagai berikut

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

3. Recall

Recall merupakan tingkat yang menunjukkan seberapa banyak objek (ground truth) yang dapat dideteksi oleh sistem. Untuk menghitung *recall* menggunakan persamaan berikut ini:

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

4. F1-Score

F1-Score merupakan nilai tengah harmonis dari presisi dan *recall*. Rentang nilai terbaik untuk *F1-Score* adalah dari 0 hingga 1. Secara praktis, jika *F1-Score* memiliki nilai yang

tinggi, itu menunjukkan bahwa model klasifikasi memiliki presisi dan *recall* yang baik. Rumus untuk F1-Score adalah sebagai berikut:

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{precision} + \frac{1}{recall} \right) \quad (3)$$

HASIL DAN PEMBAHASAN

Dataset

Dalam penelitian ini, terdapat dataset yang terdiri dari empat kelas, yaitu kelas mentah, kurang matang, matang, dan terlalu matang. Setiap kelas memiliki 100 gambar yang diambil, sehingga total gambar dalam dataset adalah 400 gambar. Contoh pengambilan gambar dapat dilihat pada gambar 2.




Gambar 3 Contoh kelas Tingkat kematangan buah nanas (A) mentah, (B) Kurang Matang, (C) Matang, (D) Terlalu Matang.

Hasil pengambilan gambar ini, selanjutnya dilakukan *preprocessing* data dan augmentasi data yang mana dalam penelitian ini akan diuji tipe augmentasi terbaik dalam pembuatan model klasifikasi Tingkat kematangan buah nanas.

Pre-processing Data

Pada tahapan *preprocessing* data dilakukan pelabelan atau anotasi data menggunakan *vgganotator* dengan memfokuskan gambar pada badan buah nanas dengan *bounding box* tipe *rectangle*. Selanjutnya dilakukan *cropping* gambar dan dilakukan *resize* gambar menjadi ukuran 224x224x3. Setelah itu, dilakukan proses augmentasi data menggunakan tiga jenis augmentasi, yaitu geometrik, fotometrik, dan kombinasi antara data asli tanpa augmentasi dengan data yang telah mengalami augmentasi geometrik dan fotometrik. Contoh augmentasi data dapat dilihat pada gambar 2.



Gambar 4 Augmentasi data.


Jenis augmentasi data dengan menggunakan transformasi fotometrik dan geometrik merupakan metode yang umum digunakan dalam sektor agrikultur. Augmentasi geometrik pada penelitian ini terdiri dari rotasi 15°, 30° serta translasi dengan rasio 0.3, kemudian pada augmentasi fotometrik terdapat random brightness dengan rentang -20% sampai 50% dan Gaussian blur dengan nilai variance 7% sampai dengan 9%. Dalam proses pembuatan model, dataset dari setiap tipe augmentasi data dibagi menjadi 70% untuk *training* data, 20% untuk *validation* data dan 10% untuk data *testing*. Total gambar yang digunakan dalam setiap augmentasi terangkum dalam table 2.

Tabel 2 Hasil Tipe Augmentasi data


Tipe	Tanpa Agumentasi	Geometrik	Fotometrik	Kombinasi
Asli	400	400	400	400
Rotasi 15	-	200	-	200
Rotasi 30	-	200	-	200
Translasi 30	-	400	-	400
Gaussian Blur	-	-	400	400
Random Brightness	-	-	400	400
Total	400	1.200	1.200	2.000

Evaluasi Model

Pada tahap awal pengujian dalam penelitian ini, dilakukan pencarian tipe augmentasi terbaik menggunakan arsitektur MobileNetV1 sebagai model dasar. Model ini diperluas dengan menambahkan *Global Average Pooling* dan *dense sioftmax* untuk empat kelas. Pembagian data yang digunakan adalah 70% untuk data latih, 20% untuk data validasi, dan 10% untuk data uji. *Optimizer* yang dipilih adalah *Adam*, dengan *batch size* sebesar 32 dan *learning rate* sebesar 0,0001. Grafik hasil akurasi dan loss dari pelatihan model ditunjukkan dalam gambar 3 dan gambar 4.



Gambar 5 Grafik Akurasi A) Tanpa Augmentasi, B) Augmentasi Geometrik, C) Augmentasi Fotometrik, D) Augmentasi Kombinasi



Gambar 6 Grafik Loss A) Tanpa Augmentasi, b) Augmentasi Geometrik, C) Augmentasi Fotometrik dan D) Augmentasi Kombinasi

Setelah dilakukan pelatihan model menggunakan tipe augmentasi data akurasi pada data training dan validasi dari data asli tanpa augmentasi mendapatkan hasil sebesar 0,8357 dan validasi sebesar 0.7250. Kemudian pengujian menggunakan *dataset geometric* mendapatkan hasil sebesar 0.90 untuk evaluasi training dan 0.8041 untuk data validasi. Hasil pengujian tipe augmentasi fotometrik mengalami peningkatan dibanding dengan augmentasi geometrik yaitu

sebesar 0.8583 untuk data validasi tetapi pada data *training* menghasilkan akurasi lebih kecil dari geometrik yaitu sebesar 0.8916. Peningkatan akurasi terjadi saat pengujian menggunakan data kombinasi yaitu gabungan dari data asli, augmentasi fotometrik dan geometrik yaitu sebesar 0.9071 untuk akurasi pelatihan dan 0.8675 untuk akurasi data validasi. Hasil pengujian menunjukkan bahwa data augmentasi dengan jenis kombinasi menghasilkan nilai *loss* terendah, dengan *training loss* sebesar 0,3353 dan *validation loss* sebesar 0,4049. Sementara itu, untuk tipe augmentasi fotometrik, *training loss* adalah 0,3696 dan *validation loss* adalah 0,4449. Nilai *loss* untuk augmentasi fotometrik ternyata lebih kecil dibandingkan dengan tipe augmentasi geometrik, yang menghasilkan *training loss* sebesar 0,4026 dan *validation loss* sebesar 0,5130. Sedangkan untuk data asli tanpa augmentasi memiliki nilai *loss* lebih tinggi dari ke tiga jenis tipe augmentasi, yaitu sebesar 0.5674 untuk *training* dan 0.6901 untuk validasi. Kemudian dilakukan pengujian menggunakan dataset test dan didapat hasil *classification report* pada table 3.

Tabel 3 Hasil *classification report* tipe augmentasi data



Augmentasi	Akurasi	Presisi	Recall	F1-SCORE
Tanpa Augmentasi	0.70	0.71	0.70	0.70
Geometrik	0.80	0.81	0.80	0.80
Fotometrik	0.8417	0.84	0.84	0.84
Kombinasi	0.8799	0.89	0.88	0.88

Pada percobaan selanjutnya dilakukan pengujian arsitektur dari AlexNet (Kanjawattana et al., 2023) menggunakan arsitektur standard alexnet yang kemudian menambahkan dense softmax sebagai layer klasifikasi Tingkat kematangan buah nanas. Selanjutnya akan melakukan percobaan menggunakan VGG16 sebagai arsitektur feature extraction nya kemudian pada top layer untuk penelitian Pardede (Pardede et al., 2021) dengan *top layer* Flatten, Dense layer dengan aktivasi relu dan klasifikasi softmax, selain itu untuk percobaan penelitian (Al Buhaisi, 2021) memodifikasi *Top layer* dengan *Global Average Pooling* dan dense layer dengan aktivasi soft max untuk klasifikasi. Pada percobaan arsitektur *baseline* untuk mobilnetV2 (Gulzar, 2023) memodifikasi *top layer* dengan menambahkan AveragePooling2D, Flatten, Dense Layer dan Dropout serta aktivasi softmax untuk klasifikasinya. Parameter yang digunakan dalam eksperimen baseline ini merujuk pada penelitian dari setiap model baseline. Dalam eksperimen ini, digunakan 50 *epoch* dengan metode *Early Stopping* dan nilai *patience* sebesar 5. Metode ini bertujuan untuk mengoptimalkan waktu pelatihan model serta menyimpan model terbaik jika tidak ada peningkatan dalam performa model. Selanjutnya akan menguji arsitektur yang diusulkan menggunakan pendekatan transfer learning dengan memanfaatkan arsitektur MobileNetV2 (Gulzar, 2023) sebagai model dasar. Kemudian, beberapa lapisan tambahan diterapkan di *top layer* untuk menyesuaikan model dengan dataset spesifik. Pertama, dilakukan penggunaan lapisan GlobalAveragePooling2D untuk mengekstrak fitur dari lapisan terakhir MobileNetV2. Selanjutnya, lapisan *dense layer* dan fungsi aktivasi ReLU digunakan untuk mengekstraksi fitur lebih lanjut dan memperkuat pemetaan fitur. Untuk mencegah overfitting, dropout diterapkan sebelum lapisan akhir. Pada lapisan akhir *dense layer* dengan fungsi aktivasi softmax dan output 4 kelas ditambahkan untuk klasifikasi Tingkat kematangan badan buah nanas. Dalam proses pelatihan, penggunaan pengurangan laju pembelajaran sebesar 0.0001 dan *early stopping* dengan nilai *patience* 10 sebagai *callback* membantu memperbaiki kinerja model dengan mencegah overfitting dan mempercepat konvergensi ke dalam nilai optimum. Dengan konfigurasi tersebut, diharapkan model dapat mencapai akurasi terbaik pada *dataset* yang digunakan dalam penelitian ini. *Dense Layer* yang digunakan melibatkan kombinasi nilai 128, 256, dan 512, serta kombinasi nilai *dropout* sebesar 0.1, 0.2, 0.3, 0.4, dan 0.5.

Tabel 4 Hasil Skenario Augmentasi Kombinasi

Arsitektur	Akurasi <i>Training</i>	Akurasi <i>Validation</i>
VGG16 (Pardede et al., 2021)	0.9992	0.8975
AlexNet (Kanjawattana et al., 2023)	0.9321	0.8845
MobileNetV2 (Gulzar, 2023) <i>Baseline</i>	0.9785	0.9150
MobileNetV2 + <i>GAP</i> + <i>Dense Layer</i> + <i>Dropout</i> (Usulan)	0.9907	0.9300

Hasil usulan model didapat nilai neuron terbaik sebesar 256 dengan nilai dropout 0.3 yang mana dalam penelitian ini mengalahkan 3 penelitian sebelumnya. Selanjutnya dilakukan evaluasi model dengan pengujian menggunakan dataset *test* yang terangkum dalam *confusion matrix* dan tabel *classification report*

**Gambar 7 Confusion matrix VGG16 (Pardede et al., 2021) dan AlexNet (Kanjawattana et al., 2023)****Gambar 8 Confusion matrix MobileNetV2 (Gulzar, 2023) dan MobileNetV2 (Usulan)**

Dari hasil confusion matrix didapat table klasifikasi report pada tabel 4.6, dari hasil pengujian menggunakan data uji hasil MobilNetV2 dengan menggunakan *GlobalAveragePooling*, *dense layer* dan *dropout* mendapatkan hasil terbaik dalam pengujian ini.

Tabel 5 Hasil *classification report* Skenario Augmentasi Kombinasi

Arsitektur	Accuracy	Precision	Recall	F1-Score
VGG16 (Pardede et al., 2021)	0.8849	0.89	0.88	0.89
AlexNet (Kanjawattana et al., 2023)	0.8750	0.88	0.88	0.87
MobileNetV2 (Gulzar, 2023) <i>Baseline</i>	0.8999	0.90	0.90	0.90
MobileNetV2 + <i>GAP</i> + <i>Dense Layer</i> + <i>Dropout</i> (Usulan)	0.9049	0.91	0.91	0.91

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil eksperimen yang telah dilakukan, dapat disimpulkan bahwa penggunaan teknik augmentasi data memiliki dampak yang signifikan terhadap kinerja model. Dari empat skenario yang diuji, kombinasi dari teknik augmentasi data geometris dan fotometris menunjukkan hasil yang paling baik. Model yang dilatih dengan kombinasi ini mencapai akurasi tertinggi baik pada data pelatihan maupun validasi, dengan nilai masing-masing mencapai 90.71% dan 86.75%. Sementara itu, penggunaan teknik augmentasi data *geometric* saja menghasilkan kinerja yang sedikit lebih rendah dengan akurasi pelatihan sebesar 86.30% dan akurasi validasi sebesar 80.41%. Penggunaan tipe augmentasi fotometrik mendapatkan akurasi sebesar 89.16% dan pada validasi mendapatkan 85.83%. Hal ini menunjukkan bahwa penggabungan berbagai jenis augmentasi data dapat membantu meningkatkan kinerja model secara signifikan. Dengan demikian, dalam pengembangan model yang memerlukan pemrosesan data yang terbatas, penggunaan teknik augmentasi data merupakan strategi yang sangat dianjurkan untuk meningkatkan kinerja model. Pada skenario eksperimen arsitektur *baseline* pada penelitian ini *MobileNetv2* mendapatkan hasil yang terbaik dibanding dengan arsitektur Vgg16 dan AlexNet. Pada pengujian model yang diusulkan dengan memodifikasi *top layer* dengan arsitektur *MobileNetv2* mendapatkan akurasi training sebesar 99,07% dan validasi sebesar 93%.

Saran

Pada penelitian selanjutnya dapat menguji beberapa tipe augmentasi data yang berfokus pada rotasi seperti perbandingan rotasi 15, 30, 45. Kemudian dapat memperbanyak dataset dengan berbagai kondisi baik cahaya, posisi, dan sudut pandang buah yang diikuti dengan ukuran buah, selain itu dapat mencoba jenis arsitektur *cnn* lainnya serta dapat diimplementasikan pada perangkat *mobile* atau *embedded system*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang terlibat dalam penelitian ini.

REFERENSI

- Al Buhaisi, H. N. (2021). Image-Based Pineapple Type Detection Using Deep Learning. *International Journal of Academic Information Systems Research*, 5(1), 2643–9026. www.ijeais.org/ijaisr
- Albarrak, K., Gulzar, Y., Hamid, Y., Mehmood, A., & Soomro, A. B. (2022). A Deep Learning-Based Model for Date Fruit Classification. *Sustainability (Switzerland)*, 14(10). <https://doi.org/10.3390/su14106339>
- Altaheri, H., Alsulaiman, M., & Muhammad, G. (2019). Date Fruit Classification for Robotic Harvesting in a Natural Environment Using Deep Learning. *IEEE Access*, 7(August), 117115–117133. <https://doi.org/10.1109/ACCESS.2019.2936536>
- Assuncao, E., Diniz, C., Gaspar, P. D., & Proenca, H. (2020). Decision-making support system

- for fruit diseases classification using Deep Learning. *2020 International Conference on Decision Aid Sciences and Application, DASA 2020, November*, 652–656. <https://doi.org/10.1109/DASA51403.2020.9317219>
- Bui, T. X., Bui, C. Van, Nguyen, L., Nguyen, P. X., & Cuong Huy, H. N. (2020). The Analysis of Ripening of Pineapple Fruits Using Machine Learning Technique. *International Journal of Machine Learning and Networked Collaborative Engineering*, 04(04), 152–161. <https://doi.org/10.30991/ijmlnce.2020v04i04.002>
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15031906>
- Junior, F. A., & Suharjito. (2023). Video based oil palm ripeness detection model using deep learning. *Heliyon*, 9(1). <https://doi.org/10.1016/j.heliyon.2023.e13036>
- Kanjanawattana, S., Teerawatthanaprapha, W., Praneetpholkrang, P., Bhakdisongkhram, G., & Weeragulpiriya, S. (2023). Pineapple Sweetness Classification Using Deep Learning Based on Pineapple Images. *Journal of Image and Graphics(United Kingdom)*, 11(1), 47–52. <https://doi.org/10.18178/joig.11.1.47-52>
- Lai, Y., Ma, R., Chen, Y., Wan, T., Jiao, R., & He, H. (2023). A Pineapple Target Detection Method in a Field Environment Based on Improved YOLOv7. *Applied Sciences (Switzerland)*, 13(4). <https://doi.org/10.3390/app13042691>
- Li, R., Ji, Z., Hu, S., Huang, X., Yang, J., & Li, W. (2023). Tomato Maturity Recognition Model Based on Improved YOLOv5 in Greenhouse. *Agronomy*, 13(2). <https://doi.org/10.3390/agronomy13020603>
- Li, Z., Jiang, X., Shuai, L., Zhang, B., Yang, Y., & Mu, J. (2022). A Real-Time Detection Algorithm for Sweet Cherry Fruit Maturity Based on YOLOX in the Natural Environment. *Agronomy*, 12(10), 1–17. <https://doi.org/10.3390/agronomy12102482>
- Miraei Ashtiani, S. H., Javanmardi, S., Jahanbanifard, M., Martynenko, A., & Verbeek, F. J. (2021). Detection of mulberry ripeness stages using deep learning models. *IEEE Access*, 9(July), 100380–100394. <https://doi.org/10.1109/ACCESS.2021.3096550>
- Nasir, I. M., Bibi, A., Shah, J. H., Khan, M. A., Sharif, M., Iqbal, K., Nam, Y., & Kadry, S. (2020). Deep learning-based classification of fruit diseases: An application for precision agriculture. *Computers, Materials and Continua*, 66(2), 1949–1962. <https://doi.org/10.32604/cmc.2020.012945>
- Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., López García, Á., Heredia, I., Malík, P., & Hluchý, L. (2019). Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, 52(1), 77–124. <https://doi.org/10.1007/s10462-018-09679-z>
- Pardede, J., Sitohang, B., Akbar, S., & Khodra, M. L. (2021). Implementation of Transfer Learning Using VGG16 on Fruit Ripeness Detection. *International Journal of Intelligent Systems and Applications*, 13(2), 52–61. <https://doi.org/10.5815/ijisa.2021.02.04>
- Phan, Q. H., Nguyen, V. T., Lien, C. H., Duong, T. P., Hou, M. T. K., & Le, N. B. (2023). Classification of Tomato Fruit Using YOLOv5 and Convolutional Neural Network Models. *Plants*, 12(4), 1–15. <https://doi.org/10.3390/plants12040790>
- Saranya, N., Srinivasan, K., & Kumar, S. K. P. (2022). Banana ripeness stage identification: a deep learning approach. *Journal of Ambient Intelligence and Humanized Computing*, 13(8), 4033–4039. <https://doi.org/10.1007/s12652-021-03267-w>
- Siricharoen, P., Yomsatieankul, W., & Bunsri, T. (2023). Fruit maturity grading framework for small dataset using single image multi-object sampling and Mask R-CNN. *Smart*

- Agricultural Technology*, 3(October 2022), 100130.
<https://doi.org/10.1016/j.atech.2022.100130>
- Suharjito, Elwirehardja, G. N., & Prayoga, J. S. (2021). Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches. *Computers and Electronics in Agriculture*, 188(March), 106359. <https://doi.org/10.1016/j.compag.2021.106359>
- Wibi Bagas N, H., Mailoa, E., & Purnomo, H. D. (2020). Deteksi Buah untuk Klasifikasi Berdasarkan Jenis dengan Algoritma CNN Berbasis YOLOv3. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(3), 476–481.
- Widyawati, W., & Febriani, R. (2021). Real-time detection of fruit ripeness using the YOLOv4 algorithm. *Teknika: Jurnal Sains Dan Teknologi*, 17(2), 205. <https://doi.org/10.36055/tjst.v17i2.12254>
- Yang, W., Ma, X., & An, H. (2023). Blueberry Ripeness Detection Model Based on Enhanced Detail Feature and Content-Aware Reassembly. *Agronomy*, 13(6), 1613. <https://doi.org/10.3390/agronomy13061613>
- Yanto, B., Jufri, J., Lubis, A., Hayadi, B. H., & Armita, NST, E. (2021). KLARIFIKASI KEMATANGAN BUAH NANAS DENGAN RUANG WARNA HUE SATURATION INTENSITY (HSI). *INOVTEK Polbeng - Seri Informatika*, 6(1). <https://doi.org/10.35314/isi.v6i1.1882>
- Zhang, X., Gao, Q., Pan, D., Cao, P. C., & Huang, D. H. (2021). Research on Spatial Positioning System of Fruits to be Picked in Field Based on Binocular Vision and SSD Model. *Journal of Physics: Conference Series*, 1748(4). <https://doi.org/10.1088/1742-6596/1748/4/042011>