

Klasifikasi Tingkat Kematangan Buah Alpukat Berdasarkan Citra Hiperspektral menggunakan Convolutional Neural Network

Murinto^{1✉}, Bella Saphira², Utin Dhea Artyandra³
¹⁻³Universitas Ahmad Dahlan, Indonesia

✉Corresponding Author: murintokusno@tif.uad.ac.id

ABSTRAK

Alpukat merupakan salah satu buah yang jarang matang di pohonnya. Hal ini dikarenakan daun pohon alpukat menghasilkan zat penghambat pematangan yang diteruskan ke buah alpukat melalui tangkai bunga. Oleh karena itu, diperlukan pengelolaan pasca panen untuk mengetahui status tingkat kematangan alpukat. Agar kualitas rantai pasok tetap terjamin saat diekspor atau ditempatkan di toko buah, diperlukan suatu metode yang dapat menentukan tingkat kematangan alpukat dengan baik. Pada penelitian ini digunakan 4 model klasifikasi untuk digunakan dalam mengklasifikasikan citra buah alpukat, yaitu Support Vector Machine (SVM), Resnet-18, VGG16 dan MobileNetV2 arsitektur Convolutional Neural Network (CNN). Citra alpukat yang digunakan dalam penelitian ini merupakan citra hiperspektral yang kemudian direduksi menggunakan teknik *principal component analysis* (PCA) dan format RGB. Ketiga jenis format citra tersebut kemudian diklasifikasi menggunakan SVM dan 3 model CNN Resnet-18, VGG16 dan MobileNetV2 tersebut. Hasil percobaan menunjukkan bahwa model VGG16 memiliki nilai akurasi paling tinggi. Akurasi overall diperoleh sebesar 0.8202 atau 82,02% , nilai F1-score sebesar 0.8105 atau 81,05% dan presisi sebesar 0.8210 atau 82,10% saat menggunakan citra dari semua kanal hiperspektral. Selanjutnya metode lain dapat digunakan untuk meningkatkan nilai akurasi seperti melakukan perubahan parameter optimasi CNN agar diperoleh hasil yang lebih optimal.

Kata Kunci: alpukat, citra hiperspektral, MobilNetV2, Resnet-18, VGG16.

A. Pendahuluan

Penelitian mempunyai tujuan untuk melakukan identifikasi penentuan tingkat kematangan buah. Berdasarkan pengetahuan tentang tingkat kematangan buah yang dimiliki, maka saat buah tersebut dijual di supermarket atau pasar tradisional tingkat kematangannya dapat diketahui dengan baik. Tingkat kematangan yang diketahui secara pasti akan mencegah penjualan buah yang terlalu matang atau belum matang. Hal ini dapat membantu pihak supermarket atau penjual di pasar tradisional untuk menentukan diskon dengan cepat, jika buah tersebut sudah terlalu matang atau kurang matang. Jenis buah-buahan seperti nanas, rambutan, tingkat kematangan dapat dengan mudah dilihat dari warna kulit buahnya. Begitu juga untuk buah-buahan lainnya seperti pisang, alpukat, mangga dan kiwi, tingkat kematangannya mudah ditentukan dari warna kulitnya.

Alpukat merupakan salah satu buah yang jarang matang di pohonnya. Hal ini dikarenakan daun pohon alpukat menghasilkan zat penghambat pematangan yang diteruskan ke buah alpukat melalui tangkai bunga. Oleh karena itu, diperlukan pengelolaan pasca panen untuk mengetahui status tingkat kematangan alpukat. Agar kualitas rantai pasok tetap terjamin saat diekspor atau ditempatkan di toko buah, diperlukan suatu metode yang dapat menentukan tingkat kematangan alpukat dengan baik.

Pencitraan hiperspektral dan jaringan syaraf (*neural networks*) dapat digunakan untuk memprediksi tingkat kematangan buah. Klasifikasi merupakan proses pengelompokan suatu objek ke dalam kelas tertentu. Proses klasifikasi juga digunakan dalam Artificial Intelligence

(AI) yaitu kecerdasan yang diciptakan oleh komputer, sehingga dapat menirukan tindakan seperti manusia pada umumnya dan dapat menangkap kejadian yang terjadi di lingkungan sekitar. Artificial Intelligence memiliki 2 sub bagian yaitu Machine Learning (ML) dan Deep Learning (DL). Deep Learning sendiri merupakan salah satu sub bagian dari Machine Learning. Dalam Deep Learning terdapat beberapa algoritma yang sudah dikenal dan sering digunakan, diantaranya: Recurrent Neural Networks (RNN)[1], Convolutional Neural Network (CNN) [2, 3,4,5] dan Deep Generative Model [6]. CNN merupakan jaringan yang dapat menggambarkan, menerima dan mengenali level target dari yang rendah sampai yang tinggi. Selain metode klasik seperti Support Vector Machine (SVM), metode deep learning juga telah digunakan oleh para peneliti di berbagai bidang seperti: pasar saham [7], citra lanskap [8], biomedis [9], dan pertanian [10,11,12], para peneliti telah berupaya mengembangkan metode berbasis deep learning untuk masalah klasifikasi buah, sebagian besar menggunakan pendekatan transfer learning seperti MobileNet [12], Restnet[13], Alexne[14], VGG16 [15], GoogleNet [16].

Penelitian yang dilakukan oleh Shahi et al (2022) [17] menyajikan modul konvolusi berbasis MobileNetV2 untuk mengklasifikasikan gambar buah. Metode ini mencapai akurasi klasifikasi yang stabil sebesar 95,75%, 96,74%, dan 96,23% pada Dataset 1 (D1), Dataset 2 (D2), dan Dataset 3 (D3). Metode yang diusulkan memiliki beberapa keterbatasan. Pertama, metode ini bergantung pada arsitektur MobilenetV2. Oleh karena itu, model ini belum dicoba dengan arsitektur yang ditentukan pengguna lainnya. Kedua, metode ini hanya menggunakan augmentasi data daring untuk eksperimen. Performa model ini dapat ditingkatkan lebih lanjut dengan menggunakan atau sebagian menggunakan teknik augmentasi data luring tingkat lanjut lainnya, seperti Generative Adversarial Network (GAN) [6]. Ketiga, kombinasi fitur yang diperoleh dari lapisan lain MobileNetV2 layak dieksplorasi untuk meningkatkan performa klasifikasi buah. Miragia et al (2021) [18] mengusulkan sistem untuk menganalisis kematangan pulp yang terdiri dari kondisi tanpa pengawasan dan tanpa batasan sehubungan dengan akuisisi gambar. Algoritma dirancang untuk bekerja dengan kondisi akuisisi fotografi yang tidak terkontrol. Oleh karena itu, pengguna dapat mengambil foto dengan perangkat apa pun, kamera, telepon pintar, dll., di lingkungan nyata, kebun, terlepas dari kondisi iklim, cahaya, fokus, dan tanpa batasan pemusatan atau zoom. Sistem memberikan akurasi 92,83% untuk tiga varietas plum menggunakan gambar yang diperoleh langsung di lapangan, Angeleno, Red Beaut, dan Black Intan, dengan siklus pematangan yang berbeda. Sistem ini menunjukkan akurasi rata-rata 95,5% dalam analisis kematangan buah plum, dengan mengetahui variasinya.

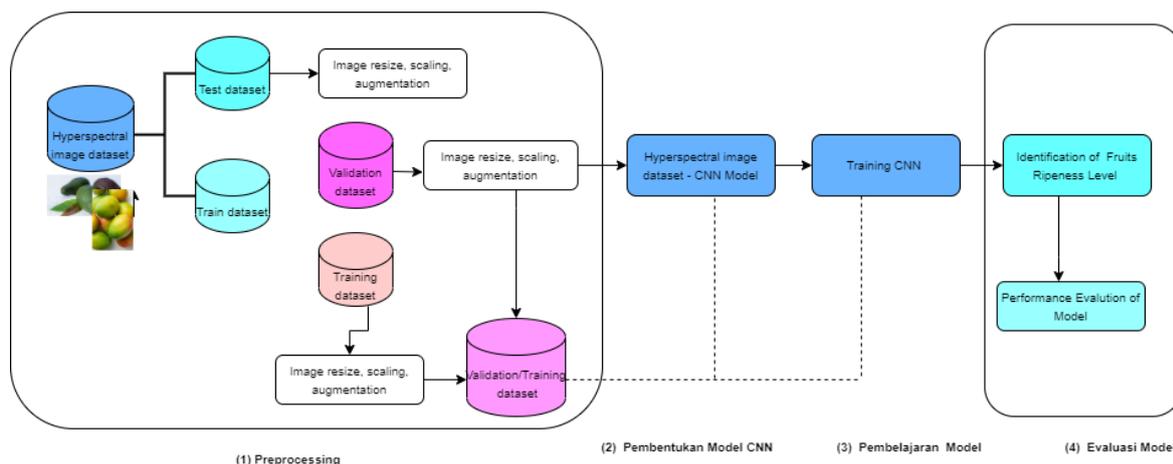
Makalah ini disusun sebagai berikut. Bagian 1 menjelaskan tentang latar belakang permasalahan yang dihadapi dalam penelitian ini. Bagian 2 menjelaskan tentang metode yang digunakan. Bagian 3 menyajikan hasil dan pembahasan penelitian klasifikasi tingkat kematangan buah berdasarkan citra hiperspektral menggunakan algoritma Convolutional Neural Network (CNN) dan Bagian 4 menjelaskan kesimpulan dan rencana kedepannya dari hasil penelitian yang dilakukan ini.

B. Metode

Dalam penelitian ini digunakan pendekatan neural networks di mana algoritma CNN diterapkan untuk proses klafisikasi tingkat kematangan buah alpukat. Hiperparameter yang optimal ini dipilih dan setelah itu evaluasi kinerja dari suatu CNN melalui studi eksperimental,

di mana parameter diubah secara manual. Nilai parameter CNN yang berbeda-beda menghasilkan hasil yang bervariasi untuk tugas yang sama. Alasan inilah yang mendasari untuk menemukan arsitektur CNN yang memberikan akurasi yang paling baik.

Parameter ini meliputi: Jumlah convolutional layer, filter size atau dimensi filter yang digunakan dalam tiap operasi konvolusi, serta jumlah ukuran batch: nilai ini merepresentasikan jumlah citra yang dimasukkan ke dalam CNN dalam tiap block. Metodologi secara umum dari penelitian ini ditunjukkan dalam Gambar 1.

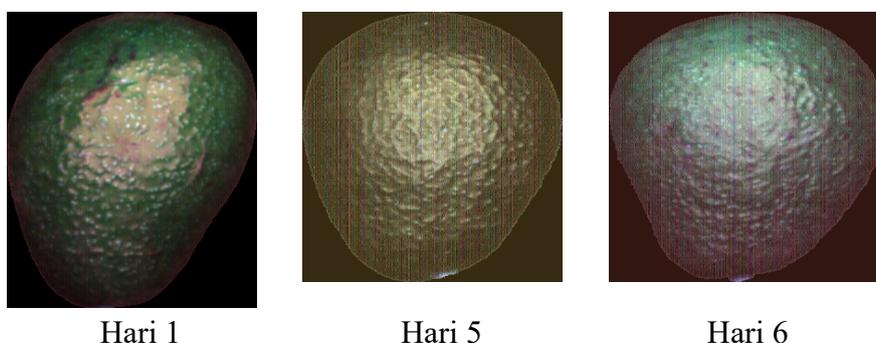


Gambar 1. Metodologi Riset Klasifikasi Tingkat Kematangan Buah Alpukat Menggunakan CNN

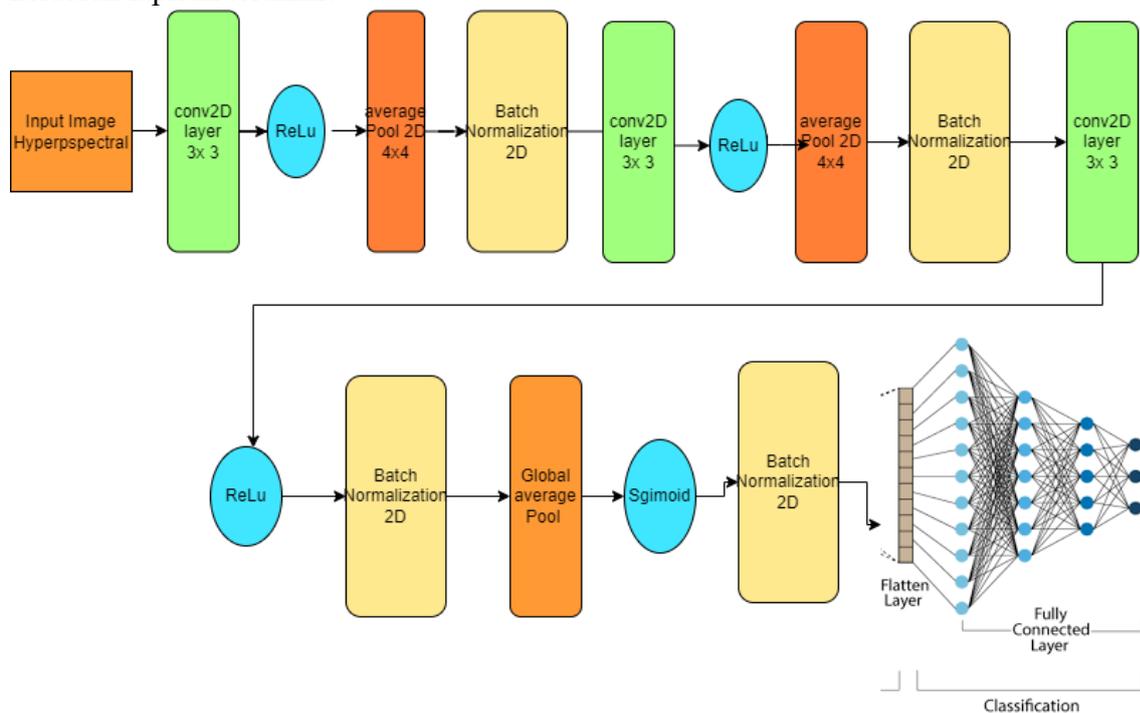
C. Hasil dan Pembahasan

1. Dataset Citra Hiperspektral Buah Alpukat

Dataset yang digunakan adalah dataset citra hiperspektral alpukat. Dataset diperoleh dari data sekunder. Tujuan utama penelitian ini adalah untuk mengetahui melakukan klasifikasi tingkat kematangan buah alpukat yang dikelompokkan menjadi belum matang (*unripe*), matang (*ripe*) dan terlalu matang (*too ripe*). Pada Gambar 2, ditampilkan visualisasi Proses Pematangan Buah Alpukat. Kumpulan data yang diperoleh dalam 11 hari mencakup data pada hari ke-1, 2, 3, 4, 5, 7, 8, 9, 10, 11, dan 12. Data citra hiperspektral buah alpukat didapat dari: <https://cogsys.cs.uni-tuebingen.de/webprojects/DeepHS-Fruit-2023-Datasets/>. Sementara itu, Histogram Buah Avocado yang Belum Matang, Matang, dan Terlalu Matang ditunjukkan pada Gambar 3.



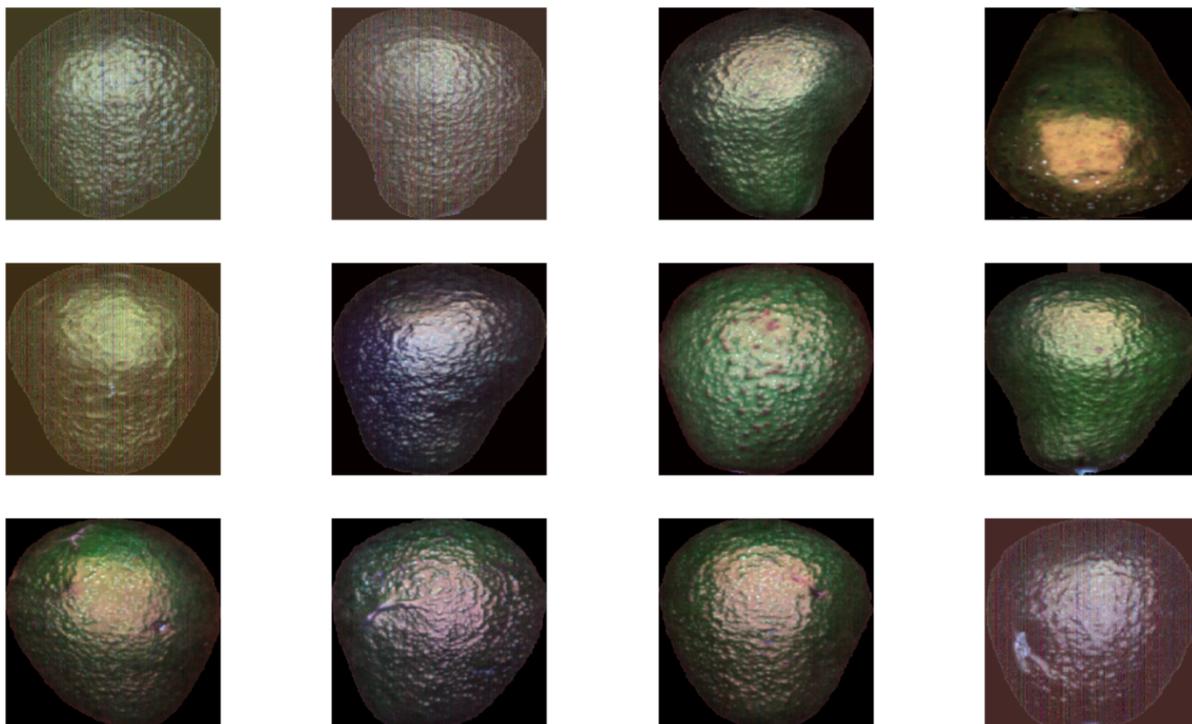
pooling digunakan sebagai pengganti lapisan max-pooling, karena memberikan hasil yang secara empiris lebih baik dalam penelitian ini. Selanjutnya, normalisasi batch digunakan untuk mempercepat proses pelatihan. Klasifikasi akhir terjadi di bagian atas CNN, yang terdiri dari lapisan pengumpulan rata-rata global dan lapisan yang terhubung penuh. Lapisan pengumpulan rata-rata global mengurangi jumlah parameter secara besar-besaran dan menghasilkan prediksi yang lebih stabil daripada bagian atas yang terhubung penuh dengan ukuran yang sama. Dalam masalah ini, jaringan mengklasifikasikan ke dalam tiga kelompok berbeda yang terlihat dalam keluaran lapisan terakhir.



Gambar 4. Klasifikasi Citra Hiperspektral Buah Alpukat Menggunakan CNN

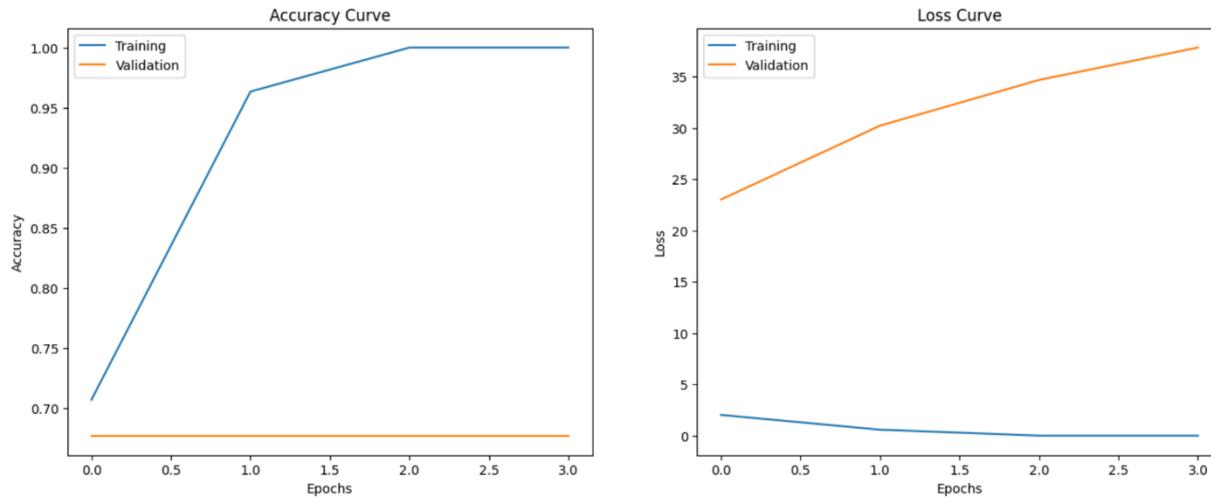
2. Pelatihan (Training)

Pelatihan yang dilakukan dalam penelitian ini, ukuran kelas dalam kelompok adalah seimbang. Maka dari itu tidak ada perbedaan terhadap satu kelas. Di sini digunakan rotasi, flipping, sebagai teknik augmentasi data. Masing-masing teknik ini tidak merubah label. *Neural network* dioptimalkan dengan menggunakan *Adabound* menggunakan 0,001 sebagai learning rate. *Focal loss* digunakan sebagai *loss function*. Dan digunakan *early stopping* didasarkan pada *validation loss* untuk mencegah *overfitting*. *Batch* yang digunakan adalah berukuran 32, sedangkan ukuran dari citra hiperspektral alpukat adalah 64 x 64 piksel. Dalam Gambar 5 diperlihatkan citra buah alpukat yang digunakan pada training.

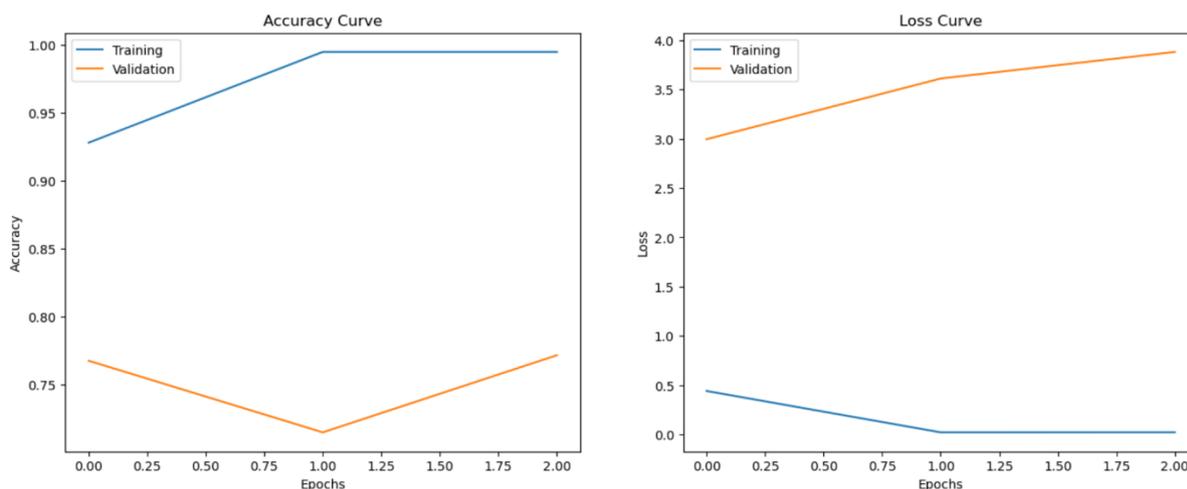


Gambar 5. Dataset Training Citra Buah Alpukat

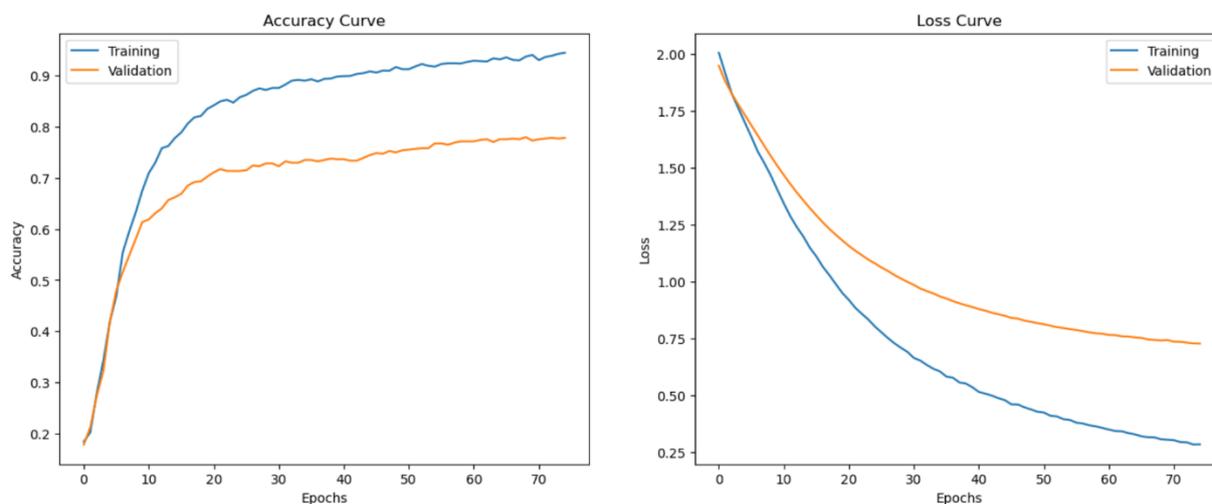
Dalam Gambar 6, Gambar 7 dan Gambar 8 secara berurutan diperlihatkan kurva akurasi dan loss training MobileNetV2, Resnet-18 dan VGG16.



Gambar 6. Kurva Akurasi dan Loss Training Model MobileNetV2



Gambar 7. Kurva Akursi dan Loss Training Model Resnet-18



Gambar 8. Kurva Akursi dan Loss Training Model VGG16

3. Pengujian (Testing)

Dalam penelitian dilakukan testing pada 4 model yaitu Support Vector Machine (SVM), VGG 16, Mobilenet dan Resnet-50V2. Hasil percobaan seperti yang diperlihatkan dalam Tabel 1. Dalam penelitian ini dilakukan pengujian 4 model pada dataset yang dipunyai. Model tersebut adalah *Support Vector Machine (SVM)* dengan kernelnya adalah *Radial Base Function*, *MobileNetV2*, *VGG16*, dan *Resnet-18*. Di dalam kasus citra RGB, rekaman hiperspektral dikurangi menjadi beberapa citra warna dalam langkah prapemrosesan. Dan untuk kasus reduksi dimensi menggunakan *principal component analysis (PCA)*, PCA digunakan untuk mengurangi ukuran saluran rekaman hiperspektral menjadi lima saluran. PCA ini sering digunakan untuk mengekstraksi rekaman hiperspektral hanya pada informasi yang diperlukan saat langkah awal. Dalam penelitian ini terlihat bahwa model VGG16 beberapa model referensi lainnya. Selain itu, ini memberikan hasil yang paling stabil. Dengan model ini, kematangan alpukat dapat diprediksi dengan menggunakan akurasi lebih dari 82,02%. Selanjutnya kasus penggunaan citra RGB alpukat dan juga PCA memberikan hasil yang lebih baik juga dibandingkan dengan model lain. Dalam Tabel 1 diperlihatkan *Accuracy Overall*

(AOA), *F1-Score* dan presisi dari hasil testing klasifikasi tingkat kematangan buah alpukat.

Tabel 1. Accuracy Over All (AOA) Tingkat Kematangan Buah Alpukat

Methods	Image	Ripeness (Overall Accuracy)	Ripeness (F1-Score)	Ripeness (Presisi)
SVM	Full	0.7851	0.7743	0.7921
	RGB	0.8275	0.8164	0.8453
Resnet-18	PCA	0.5334	0.5230	0.5432
	Full	0.8102	0.8145	0.8341
	RGB	0.7655	0.7567	0.7921
VGG16	PCA	0.5345	0.5215	0.5410
	Full	0.8202	0.8105	0.8210
	RGB	0.6774	0.6574	0.6775
MobileNetV2	PCA	0.5532	0.5432	0.5732
	Full	0.8014	0.8001	0.8305

D. Simpulan

Pada penelitian ini diusulkan model klasifikasi convolutional network untuk digunakan dalam mengklasifikasikan citra buah alpukat. Citra alpukat yang digunakan dalam penelitian ini merupakan citra hyperspectral yang kemudian direduksi menggunakan teknik principal component analysis (PCA) dan format RGB. Ketiga jenis format citra tersebut kemudian diklasifikasi menggunakan model CNN Resnet-18, VGG16 dan MobileNetV2. Hasil percobaan menunjukkan bahwa model VGG16 memiliki nilai akurasi paling tinggi. Akurasi overall diperoleh sebesar 0.8202 atau 82,02% , nilai F1-score sebesar 0.8105 atau 81,05% dan presisi sebesar 0.8210 atau 82,10% saat menggunakan citra dari semua kanal hiperspektral. Metode lain dapat digunakan untuk meningkatkan nilai akurasi seperti melakukan perubahan parameter optimasi CNN agar diperoleh hasil yang lebih optimal.

Daftar Pustaka

- [1] H. S. Gill, O. I. Khalaf, Y. Alotaibi, S. Alghamdi, and F. Alassery, "Fruit Image Classification Using Deep Learning," *Comput. Mater. Contin.*, vol. 71, no. 2, pp. 5135–5150, 2022, doi: 10.32604/cmc.2022.022809.
- [2] A. D. M. Africa, "Ripe Fruit Detection and Classification using Machine Learning," *Int. J. Emerg. Trends Eng. Res.*, vol. 8, no. 5, pp. 1845–1849, 2020, doi: 10.30534/ijeter/2020/60852020.
- [3] F. E. Fernandes Junior and G. G. Yen, "Particle swarm optimization of deep neural networks architectures for image classification," *Swarm Evol. Comput.*, vol. 49, no. June, pp. 62–74, 2019, doi: 10.1016/j.swevo.2019.05.010.
- [4] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, no. February, pp. 70–90, 2018, doi: 10.1016/j.compag.2018.02.016.
- [5] N. Nurkhasanah and M. Murinto, "Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network," *Sainteks*, vol. 18, no. 2, p. 183, 2022, doi: 10.30595/sainteks.v18i2.13188.
- [6] S. Mo, "Deep Learnin," *Nature*, v. 26, no. January, pp. 1102–1109, 2020.
- [7] M. Hiransha, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman, "NSE Stock Market Prediction Using Deep-Learning Models," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 1351–1362, 2018, doi: 10.1016/j.procs.2018.05.050.

- [8] D. Buscombe and A. C. Ritchie, "Landscape classification with deep neural networks," *Geosci.*, vol. 8, no. 7, pp. 1–23, 2018, doi: 10.3390/geosciences8070244.
- [9] L. D. Nguyen, D. Lin, Z. Lin, and J. Cao, "Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation," *Proc. - IEEE Int. Symp. Circuits Syst.*, vol. 2018-May, 2018, doi: 10.1109/ISCAS.2018.8351550.
- [10] 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, 2022, doi: 10.1155/2022/9210947.
- [11] Herman, A. Susanto, T. Wawan Cenggoro, Suharjito, and B. Pardamean, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," *J. Telecommun. Electron. Comput. Eng.*, vol. 12, no. 2, pp. 21–27, 2020, [Online]. Available: <https://jtec.utem.edu.my/jtec/article/view/5543>.
- [12] M. Masum, H. Shahriar, and H. M. Haddad, "A Transfer Learning with Deep Neural Network Approach for Network Intrusion Detection," vol. 12, no. 1, pp. 1087–1095, 2021.
- [13] H. K. Jeon, S. Kim, J. Edwin, and C. S. Yang, "Sea fog identification from GOCI images using CNN transfer learning models," *Electron.*, vol. 9, no. 2, pp. 1–9, 2020, doi: 10.3390/electronics9020311.
- [14] Z. Gao, Y. Shao, G. Xuan, Y. Wang, Y. Liu, and X. Han, "Real-time hyperspectral imaging for the in-field estimation of strawberry ripeness with deep learning," *Artif. Intell. Agric.*, vol. 4, pp. 31–38, 2020, doi: 10.1016/j.aiaa.2020.04.003.
- [15] A. Waheed, M. Goyal, D. Gupta, A. Khanna, A. E. Hassanien, and H. M. Pandey, "An optimized dense convolutional neural network model for disease recognition and classification in corn leaf," *Comput. Electron. Agric.*, vol. 175, no. January, p. 105456, 2020, doi: 10.1016/j.compag.2020.105456.
- [16] S. Bunrit, N. Kerdprasop, and K. Kerdprasop, "Evaluating on the transfer learning of CNN architectures to a construction material image classification tasks," *Int. J. Mach. Learn. Comput.*, vol. 9, no. 2, pp. 201–207, 2019, doi: 10.18178/ijmlc.2019.9.2.787.
- [17] 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 February, pp. 1–21, 2022, doi: 10.1371/journal.pone.0264586.
- [18] R. Miragaia, F. Chávez, J. Díaz, A. Vivas, M. H. Prieto, and M. J. Moñino, "Plum Ripeness Analysis in Real Environments Using Deep Learning with Convolutional Neural Networks," *Agronomy*, vol. 11, no. 11, pp. 1–26, 2021, doi: 10.3390/agronomy11112353.
- [19] N. M. T. Nguyen and N. S. Liou, "Ripeness Evaluation of Achacha Fruit Using Hyperspectral Image Data," *Agric.*, vol. 12, no. 12, 2022, doi: 10.3390/agriculture12122145.
- [20] M. Fahmy Amin, "Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial," *J. Eng. Res.*, vol. 7, no. 1, pp. 0–0, 2023, doi: 10.21608/erjeng.2023.296718.
- [21] A. Rikhtegar, M. Pooyan, and M. T. Manzuri, "Comparing performance of metaheuristic algorithms for finding the optimum structure of CNN for face recognition," *Int. J. Nonlinear Anal. Appl.*, vol. 11, no. 1, pp. 301–319, 2020, doi: 10.22075/ijnaa.2020.4296.