

Pengembangan Multimodal Convolutional Neural Network untuk *Grading* Buah Jambu Kristal dengan Dua Perspektif Citra

Yusrian Asghany¹, Rizal Setya Perdana², Budi Darma Setiawan³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹yusrianasghany@student.ub.ac.id, ²rizalespe@ub.ac.id, ³s.budidarma@ub.ac.id

Abstrak

Indonesia merupakan negara dengan sektor pertanian yang memiliki potensi besar, salah satu produk unggulannya adalah buah-buahan. Terdapat beberapa komoditas buah-buahan di Indonesia yang belum mendapatkan perhatian yang seharusnya, contohnya adalah buah jambu kristal. Upaya peningkatan pemanfaatan jambu kristal dapat dicapai dengan mengoptimalkan proses produksinya. Pengoptimalan ini dapat dicapai dengan menerapkan otomatisasi pada berbagai tahap, dan tahapan *grading* menjadi salah satu aspek yang sangat menguntungkan. Proses *grading* dapat diotomatisasi dengan pendekatan *computer vision*, lebih spesifik Multimodal Convolutional Neural Network (CNN). Pendekatan ini melakukan *grading* buah jambu kristal dengan masukan citra atas dan citra samping buah. Pendekatan CNN biasa tidak dapat menerima lebih dari satu modalitas sehingga penciri kualitas buah yang diperoleh lebih terbatas dan sangat mungkin untuk tidak mencukupi untuk *grading* dengan benar. Penelitian dilakukan dengan membangun model Multimodal CNN yang dapat menerima dua macam citra tadi dan menghasilkan prediksi kualitas buah jambu kristal. Model dilatih dengan data pasangan citra atas dan citra samping buah jambu kristal yang sudah melalui pemrosesan awal. Model dengan kinerja terbaik didapatkan dengan penerapan *optimizer* Adam tanpa *scheduler* dan *learning rate* awal sebesar 0.001 pada proses pelatihannya terhadap data yang mendapatkan pemrosesan awal secara lengkap. Model ini mendapatkan nilai akurasi 0.95 dan *F1 score* 0.95.

Kata kunci: *computer vision, Convolutional Neural Network, grading, jambu kristal, multimodal, Multimodal CNN*

Abstract

Indonesia, with its significant agricultural sector, boasts vast potential, particularly in fruit production. One often overlooked commodity is the crystal guava. Enhancing the utilization of crystal guava involves optimizing its production processes. Automation plays a pivotal role, especially in the grading phase. Automating the grading process using a computer vision approach, specifically a Multimodal Convolutional Neural Network (CNN), proves highly beneficial. This CNN-based approach grades crystal guavas using both top-view and side-view images. Conventional CNNs are limited to a single modality, potentially compromising the adequacy of fruit quality characterization for accurate grading. The study introduces a Multimodal CNN model capable of processing both image modalities and predicting crystal guava quality. The model is trained on pre-processed image pairs of the top and side views of crystal guavas. The best-performing model employs the Adam optimizer without a scheduler, utilizing an initial learning rate of 0.001 during comprehensive training on pre-processed data. This model achieves an impressive accuracy and F1 score of 0.95.

Keywords: *computer vision, Convolutional Neural Network, grading, crystal guava, multimodal, Multimodal CNN*

1. PENDAHULUAN

Indonesia merupakan negara dengan sektor pertanian yang memiliki potensi besar. Dilansir dari situs Kementerian Perdagangan, 4 dari 5 besar komoditas ekspor terbesar Indonesia

adalah produk pertanian. Dalam sektor ini, salah satu produk unggulan yang sangat berpotensi adalah buah-buahan. Nilai ekspor buah-buahan Indonesia pada tahun 2022 sebesar 769.919 ton atau senilai 522.157 USD dan diproyeksikan akan meningkat atau stabil (Badan Pusat

Statistik, 2023). Di sisi lain, masih ada beberapa komoditas buah-buahan di Indonesia yang belum mendapatkan perhatian yang seharusnya. Salah satu contohnya adalah buah jambu kristal. Buah asal Taiwan ini diperkenalkan di Indonesia pada tahun 2009 dan sejak itu terus mengalami perkembangan pesat (Sasmi, et al., 2022). Pengembangan lebih lanjut dalam produksi jambu kristal dapat berpotensi menguntungkan perekonomian, khususnya bagi petani lokal.

Upaya pengembangan jambu kristal dapat dicapai dengan mengoptimalkan proses produksinya. Pengoptimalan ini dapat dicapai dengan menerapkan otomatisasi pada berbagai tahap, dan tahapan *grading* menjadi salah satu aspek yang sangat menguntungkan. Proses otomatisasi tahap ini memungkinkan buah jambu kristal yang dihasilkan untuk memenuhi standar kualitas yang telah ditetapkan dengan konsistensi yang tinggi. Hal ini dapat meningkatkan reputasi produk dan memenuhi harapan konsumen. Otomatisasi juga membawa manfaat efisiensi dalam produksi. Kerja manual yang intensif dalam proses *grading* dapat dikurangi secara signifikan, mengurangi ketergantungan pada tenaga kerja manusia. Secara keseluruhan, otomatisasi pada tahap *grading* dapat mengoptimalkan proses produksi buah jambu kristal.

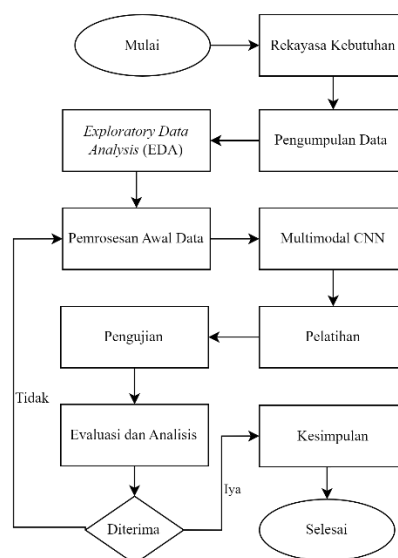
Grading otomatis buah jambu kristal dapat diwujudkan melalui pendekatan *computer vision*. Pemanfaatan *computer vision* untuk menilai kualitas buah bukanlah hal yang baru. Banyak penelitian yang telah melakukan hal yang serupa dengan objek buah yang lain. Seperti penelitian Chakraborty, et al. (2023) yang mengembangkan sistem *grading* buah jeruk berdasarkan citra serta beratnya dan penelitian Malesse, et al. (2022) yang mengembangkan sistem deteksi kematangan buah pisang berdasarkan citranya. Pada buah jambu kristal, *computer vision* dapat digunakan untuk mengidentifikasi *grade* atau kelas yang sesuai dengan mengenali buah berdasarkan ukuran dan mendeteksi cacat seperti bercak, keriput, atau goresan pada kulit buah.

Masalah yang muncul pada *grading* buah jambu kristal dengan pendekatan *computer vision* dan *deep learning* umum adalah perspektif. Bentuk dan ukuran buah tidak dapat ditentukan dengan baik menggunakan satu perspektif saja. Cacat fisik seperti goresan dan busuk sebagian juga mungkin terlewat. Diperlukan pendekatan yang bisa melakukan *grading* berdasarkan beberapa perspektif.

Pendekatan untuk masalah tersebut adalah Multimodal Convolutional Neural Network (CNN). Multimodal CNN merupakan perkembangan dari CNN yang digunakan untuk mengklasifikasikan citra. Multimodal adalah strategi pembelajaran mesin yang menggabungkan beberapa modalitas untuk meningkatkan pembelajaran dan pengambilan keputusan dalam berbagai aplikasi (Haouhat, et al., 2023).

Multimodal CNN untuk *grading* buah jambu kristal dirancang untuk dapat menerima input dari dua perspektif, yaitu citra dari atas dan citra dari samping dari buah. Dengan menggunakan dua jenis citra ini, Multimodal CNN dapat menerima informasi yang lebih lengkap dan valid dari setiap buah jambu kristal yang sedang dinilai. Hal ini membuat tahap *grading* dapat menjadi lebih sensitif terhadap variasi buah jambu kristal dengan mendapat penciri seperti ukuran, bentuk, dan tekstur, yang lebih sulit dideteksi jika hanya menggunakan satu perspektif. Penerapan Multimodal CNN untuk otomatisasi *grading* buah jambu kristal diharapkan dapat memberikan kinerja yang lebih baik dibandingkan pendekatan CNN dasar.

2. METODE PENELITIAN



Gambar 1. Diagram alir penelitian

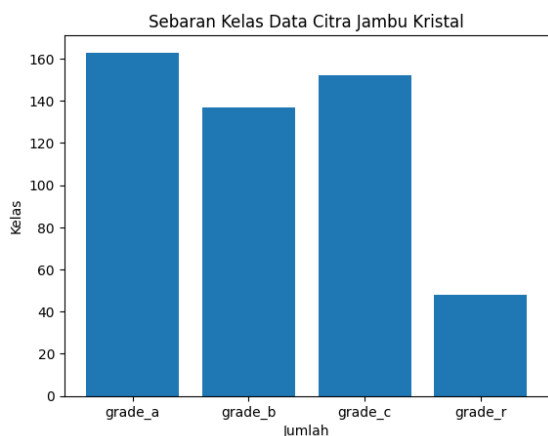
Langkah-langkah pada penelitian ini dapat dilihat pada Gambar 1. Rekayasa kebutuhan dalam dilakukan untuk lebih memahami permasalahan alami yang menjadi urgensi dilakukannya penelitian. Melalui tahap ini, penulis memahami bahwa sistem untuk melakukan *grading* buah jambu kristal diperlukan. Hal ini dapat dicapai dengan

membuat model berbasis *computer vision*. Data yang digunakan pada penelitian ini adalah data primer yang diambil dari petani jambu kristal dengan *ground truth* yang dibuat oleh pakar (petani).

Lalu, Tahapan EDA dilakukan untuk lebih memahami karakteristik data yang dimiliki. Hal ini dilakukan untuk bisa menentukan strategi terbaik untuk membangun model dari data. Setelah melalui proses ekstraksi citra dari video, didapati bahwa jumlah dari data adalah 500 buah jambu kristal yang dapat diekstrak citra dari atas dan sampingnya. Citra berupa gambar buah jambu dari konveyor dengan pengondisian yang disamakan. Berikut merupakan hasil EDA. Gambar 2 menunjukkan citra dari buah jambu yang sama, namun dari perspektif yang berbeda. Gambar 3 menunjukkan sebaran data tiap kelas. Gambar 4 menunjukkan contoh citra tiap kelas.



Gambar 2. Citra buah jambu kristal dari dua perspektif




Gambar 3. Sebaran kelas data citra jambu kristal



Gambar 4. Citra samping buah jambu

Berdasarkan EDA yang dilakukan, dapat ditentukan pemrosesan awal dan pembuatan model yang sesuai. Data perlu diaugmentasi untuk menyeimbangkan distribusi data tiap kelas. Buah jambu pada citra juga perlu ditonjolkan untuk lebih mencirikan kelas, dilakukan dengan penghapusan latar belakang. Model Multimodal CNN akan dibangun dengan strategi *intermediate fusion* dengan *backbone* CNN untuk citra atas dan citra samping. Lalu pada ujung model diterapkan DNN (Dense Neural Network) untuk menghubungkan kedua CNN dan melakukan klasifikasi. Arsitektur dasar model dapat dilihat pada Gambar 5 berikut.



Gambar 5. Arsitektur dasar model

Pengujian, evaluasi dan analisis yang dilakukan dalam penelitian ini akan dikembangkan berdasarkan metrik pengujian yang dihasilkan. Metrik-metrik pengujian yang umum dipakai dalam menilai klasifikasi adalah akurasi, presisi, *recall*, dan *F1 score*. Metrik-metrik tersebut digunakan untuk melakukan analisis kuantitatif dalam penelitian dengan hasil pengujian lainnya seperti waktu komputasi dan parameter terkait.

3. DASAR TEORI

3.1. Citra Digital

Citra digital adalah representasi elektronik dari sebuah foto, gambar, atau karya seni yang dikodekan dalam bentuk biner dan disimpan di dalam sistem elektronik seperti komputer, tablet,

atau *smartphone* (Wilson, 2023). Pada citra digital yang berbasis piksel, data visual direpresentasikan sebagai matriks 2 dimensi yang setiap elemennya mewakili 1 piksel. Setiap piksel memiliki informasi digital yang berisi intensitas (warna, kecerahan, dan lainnya). Susunan dari piksel-piksel tersebut dapat membentuk citra utuh.

3.3. Computer Vision

Tujuan dari *computer vision* adalah memberikan komputer kemampuan yang mirip dengan fungsi mata manusia dan mewujudkan “kemampuan melihat” (Matsuzaka & Yashiro, 2023). Kemampuan melihat yang dimaksudkan disini bukan hanya menangkap informasi visual, melainkan juga memahaminya melalui citra dari kamera. Bidang *computer vision* makin berkembang dengan penggunaan metode *deep learning*, pembelajaran mesin berbasis jaringan saraf tiruan, untuk berbagai tugas. *Deep learning* mampu melakukan melakukan tugas *computer vision* seperti klasifikasi dan deteksi objek dengan baik. Penggunaan *deep learning* di *computer vision* memiliki berbagai manfaat penting dan aplikasi yang luas, seperti otomatisasi di berbagai bidang dan penerapan keamanan berbasis biometrik.

3.4. Multimodal

Multimodal dalam konteks pembelajaran mesin adalah strategi pembelajaran mesin yang menggabungkan beberapa modalitas (seperti teks, gambar, dan audio) untuk meningkatkan pembelajaran dan pengambilan keputusan dalam berbagai aplikasi (Haouhat, et al., 2023). Penggabungan modalitas ini juga memiliki berbagai macam strategi. Strategi multimodal dapat dibagi menjadi 3 jenis, yaitu *late fusion* (tingkat keputusan), *intermediate/joint fusion* (tingkat fitur) dan *early fusion* (tingkat data) (Verma, 2023). Penggabungan modalitas tidak terbatas pada modalitas yang berbeda wujud saja. Modalitas dengan wujud yang sama tetapi dalam keadaan yang berbeda dapat dianggap sebagai modalitas yang berbeda dan dapat dikombinasikan. Misalkan saja strategi multimodal dengan modalitas dua citra dari objek yang sama, tetapi dalam perspektif yang berbeda.

3.5. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis khusus dari jaringan saraf *multilayer*

atau lebih dikenal dengan arsitektur *deep learning* yang terinspirasi oleh sistem visual makhluk hidup. CNN sangat cocok digunakan dalam *computer vision* dan pemrosesan bahasa alami (Ghosh, et al., 2019). CNN bekerja dengan baik pada citra dan teks karena arsitekturnya, yang secara umum terdiri dari lapisan konvolusi, lapisan *pooling*, dan lapisan *dense*. Jaringan saraf dasar yang hanya terdiri dari lapisan *dense* memiliki kinerja yang kurang pada data citra karena diasumsikan bahwa setiap piksel adalah fitur independen. Lapisan konvolusi dapat mengatasi permasalahan tersebut.

Konvolusi adalah metode matematika dari transformasi integral dan merupakan operasi penting dalam matematika analitis. Konsep konvolusi juga dapat diperluas ke dalam urutan, ukuran, dan fungsi umum (Zou, 2023). Konvolusi pada pemrosesan citra dilakukan dengan mengalikan sebuah kernel ke setiap piksel citra. Proses ini digunakan untuk berbagai tujuan seperti meratakan, mempertajam, mengurangi *noise*, dan mendeteksi tepi citra. Persamaan dari operasi konvolusi dijabarkan pada Persamaan 1.

$$h(x, y) = \sum_{a=-n}^n \sum_{b=-n}^n f(a, b) \cdot g(x - a, y - b) \quad (1)$$

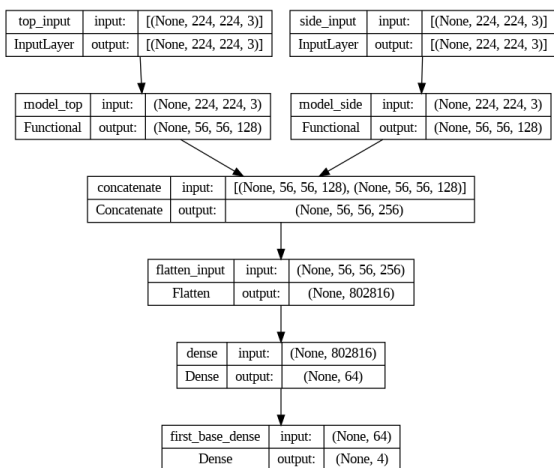
Pooling adalah teknik yang digunakan untuk mengurangi dimensi citra dengan memilih nilai maksimum, minimum, atau rata-rata dalam ukuran jendela tertentu (Imran, Aamir, & Ilyas, 2022). Teknik ini dilakukan dengan harapan meringankan komputasi dan mempercepat perhitungan tanpa menghilangkan informasi penting dari data. *Pooling* pada citra umumnya dilakukan setelah proses konvolusi.

Terakhir, *Fully Connected Layer* (FCN) adalah bagian dari CNN. Lapisan ini memiliki arsitektur yang sama dengan lapisan *dense* pada jaringan saraf tiruan normal. Tugas utama dari lapisan ini adalah melakukan transformasi data dan melakukan klasifikasi dari data hasil konvolusi. Dengan kata lain, ‘fitur’ dari citra diklasifikasikan pada lapisan ini.

4. HASIL DAN PEMBAHASAN


Penelitian menghasilkan beberapa model yang dibedakan dengan skema pelatihan dan persiapan data. Perbedaan skema ini mencakup pemilihan optimizer, penggunaan scheduler, pemilihan arsitektur, dan pemrosesan awal data. Pelatihan dilakukan sebanyak 100 *epoch* dan model yang akan digunakan untuk

merepresentasikan perlakuan tertentu adalah model dengan akurasi validasi tertinggi selama proses pelatihan. Pemeriksaan akurasi validasi tertinggi ini dilakukan setiap *epoch* berakhir. Adapun arsitektur model final yang digunakan pada penelitian ini dapat dilihat pada Gambar 6 berikut.



Gambar 6. Arsitektur model

Arsitektur untuk *model_top* dan *model_side* yang merupakan CNN untuk citra atas dan samping sama. Arsitektur ini dapat dilihat pada Gambar 7 berikut.



Gambar 7. Arsitektur model CNN

Pada pengujian berdasarkan *scheduler*, dilakukan dua skema pelatihan. Yaitu dengan dan tanpa *scheduler*. Lalu pada pengujian berdasarkan *optimizer*, dilakukan tiga skema pelatihan dengan menggunakan *optimizer* yang berbeda. *Optimizer* yang diimplementasikan adalah Adam, RMSprop, dan SGD dengan parameter *learning rate* sebesar 0.001. Pengujian berdasarkan arsitektur dilakukan dengan membandingkan model dengan

arsitektur yang berbeda. Lebih tepatnya, model Multimodal CNN dengan CNN biasa. Model Multimodal CNN dibangun seperti tahapan implementasi yang telah dijabarkan sebelumnya, sedangkan model CNN biasa dibangun dengan ‘setengah’ arsitektur Multimodal CNN. Model CNN ini menerima input berupa citra atas atau samping dari buah jambu. Terakhir, dilakukan pengujian ablasi. Pengujian ablasi dilakukan dengan melatih dan menguji model menggunakan data yang berbeda. Data yang berbeda disini didapatkan dari lengkap tidaknya pemrosesan awal yang dilakukan. Skema data yang digunakan untuk melatih dan menguji data ada empat macam, yaitu data dengan augmentasi dan *color thresholding*, data tanpa augmentasi, data tanpa *color thresholding* serta data tanpa augmentasi dan *color thresholding*.

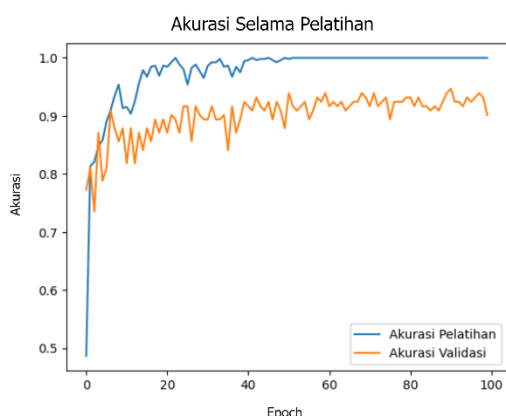
Setelah dilakukan pelatihan dan pengujian untuk masing-masing model, didapati hasil yang berbeda. Metrik yang digunakan untuk membandingkan model adalah akurasi dan *F1 score*. Berikut merupakan tabel hasil pengujian model.

Tabel 1. Hasil pengujian model

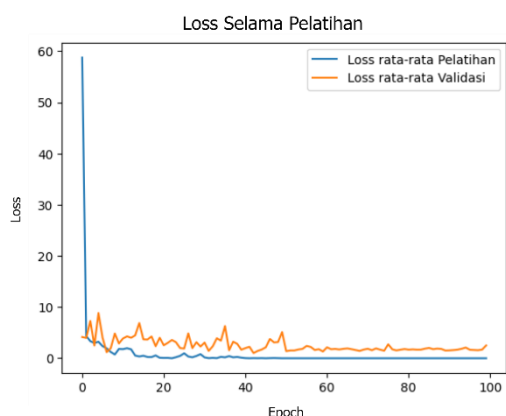
No	Model	Waktu Pelatihan (s)	Waktu Pengujian (s)	Akurasi	F1 Score
1	Dengan <i>scheduler</i>	686.17	0.66	0.93	0.93
2	Tanpa <i>scheduler</i>	669.21	0.60	0.95	0.95
3	<i>Optimizer</i> Adam	669.21	0.60	0.95	0.95
4	<i>Optimizer</i> RMSprop	664.18	0.60	0.66	0.61
5	<i>Optimizer</i> SGD	648.11	0.62	0.86	0.85
6	Multimodal CNN	669.21	0.60	0.95	0.95
7	CNN atas	367.42	0.42	0.77	0.77
8	CNN samping	373.70	0.40	0.52	0.52
9	Dengan <i>preprocessing</i>	669.21	0.60	0.95	0.95
10	Tanpa augmentasi	519.08	0.48	0.89	0.89
11	Tanpa <i>color thresholding</i>	676.74	0.59	0.92	0.92

No	Model	Waktu Pelatihan (s)	Waktu Pengujian (s)	Akurasi	F1 Score
12	Tanpa augmentasi dan <i>color thresholding</i>	521.73	0.48	0.88	0.84

Dari setiap pengujian yang telah dilakukan, didapatkan konfigurasi data, model, dan pelatihan yang terbaik. Model memberikan kinerja yang lebih baik tanpa penggunaan *scheduler*. Lalu pada penggunaan *optimizer*, Adam memberikan hasil yang lebih baik dari RMSprop dan SGD. Arsitektur Multimodal CNN sendiri diketahui memberikan kinerja yang jauh lebih baik dibandingkan CNN biasa. Tahapan pemrosesan awal berupa augmentasi dan *color thresholding* juga dapat meningkatkan kinerja model jika dinilai dari metrik-metrik yang didapatkan. Model ini selanjutnya akan disebut sebagai model utama.



Gambar 8. Akurasi selama pelatihan model utama



Gambar 9. Loss selama pelatihan model utama

Tabel 2. Hasil pengujian model utama

Label	Presisi	Recall	F1 score	Support
grade_a	0.97	0.97	0.97	33
grade_b	0.91	0.88	0.89	33
grade_c	0.91	0.97	0.94	33

Label	Presisi	Recall	F1 score	Support
grade_r	1.00	0.97	0.98	33
	Akurasi		0.95	132

Model utama dapat dikatakan cukup baik dengan akurasi yang memiliki tren naik dan loss yang memiliki tren turun. Tetapi, terdapat perbedaan akurasi validasi yang lebih rendah dan *loss* validasi yang lebih tinggi. Hal ini menunjukkan gejala *overfitting* yang ringan pada model utama. Secara keseluruhan, model utama memiliki kinerja yang baik dengan akurasi 0.95 dan *F1 score* 0.95.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Penelitian yang dilakukan berhasil mengembangkan Multimodal CNN untuk grading buah jambu kristal dengan akurasi mencapai 0.95 pada model utama. Model utama dilatih sebanyak 100 *epoch* dengan *optimizer* Adam tanpa *scheduler* dan *learning rate* awal sebesar 0.001. Model dilatih dan diuji dengan data hasil augmentasi dan *color thresholding*. Konfigurasi ini dapat mengungguli model lainnya jika dinilai dari akurasi, antara lain model dengan *scheduler* (0.93), model dengan *optimizer* lain (0.66 dan 0.86), model CNN satu modalitas (0.77 dan 0.52), dan model dengan skema pemrosesan awal lain (0.89, 0.92, dan 0.88).

Model utama memiliki kekurangan dalam mengklasifikasikan kelas *grade_b* dibandingkan kelas lainnya, dapat dilihat dari pencapaian nilai *recall* yang paling rendah (0.88). Nilai ini tidak bisa dikatakan buruk, tetapi *recall* tersebut menunjukkan titik terlemah model. Model juga mengindikasikan adanya gejala *overfitting* ringan dengan nilai *loss* validasi yang sedikit lebih tinggi dari *loss* pelatihan dan akurasi validasi yang sedikit lebih rendah dari akurasi pelatihan. Meskipun begitu, secara keseluruhan model sudah mampu melakukan generalisasi setiap kelas dengan baik. Dibuktikan dengan nilai akurasi 0.95 dan *F1 score* 0.95.

5.2. Saran

Berikut ini beberapa saran yang dapat dipertimbangkan berdasarkan hasil yang didapatkan dari penelitian.

1. Perancangan arsitektur multimodal yang lebih kompleks untuk meningkatkan kinerja dan fungsionalitas model.

2. Penambahan jumlah data latih dan validasi untuk mendapatkan model dengan kemampuan generalisasi yang lebih baik.
3. Pengembangan sistem *grading* untuk keberlanjutan penelitian.

DAFTAR PUSTAKA

- Badan Pusat Statistik, 2023. Ekspor Buah-Buahan Tahunan menurut Negara Tujuan Utama. [online] Badan Pusat Statistik. Tersedia di: <<https://www.bps.go.id/statistictable/2019/02/18/2020/ekspor-buah-buahan-tahunan-menurut-negara-tujuan-utama-2012-2022.html>> [Diakses 12 Oktober 2023]
- Chakraborty, S.K., Subeesh A., Dubey, K., Jat, D., Chandel, N.S., Potdar, R., Rao, N.R.N.V.G., Kumar, D., 2023. Development of an optimally designed real-time automatic citrus fruit grading-sorting machine leveraging computer vision-based adaptive deep learning model. *Engineering Applications of Artificial Intelligence*.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De, D., 2020. Fundamental Concepts of Convolutional Neural Network. In: Balas, V., Kumar, R., Srivastava, R. (eds) *Recent Trends and Advances in Artificial Intelligence and Internet of Things*. Intelligent Systems Reference Library, vol 172. Springer, Cham. https://doi.org/10.1007/978-3-030-32644-9_36
- Gurubelli, Y., Ramanathan, M., & Ponnusamy, P., 2019. Fractional fuzzy 2DLDA approach for pomegranate fruit grade classification. *Computers and Electronics in Agriculture*, 162, 95-105.
- Gyanendra K. Verma, 2023. Multimodal Affective Information Fusion, Multimodal Affective Computing: Affective Information Representation, Modelling, and Analysis 1: 49. <https://doi.org/10.2174/9789815124453123010008>
- Haouhat, A., Bellaouar, S., Nehar, A., & Cherroun, H., 2023. Modality Influence in Multimodal Machine Learning. arXiv preprint arXiv:2306.06476.
- Huang, S. C., Pareek, A., Seyyedi, S., Banerjee, I., & Lungren, M. P., 2020. Fusion of medical imaging and electronic health records using deep learning: a systematic review and implementation guidelines. *NPJ digital medicine*, 3(1), 136.
- Imran, H., Aamir, K., & Ilyas, M. (2022). Convolutional Neural Network (CNN) with Randomized Pooling.
- Kalamkar S, Mary A.G, 2023. Multimodal image fusion: A systematic review. *Decision Analytics Journal* Volume 9, 100327, ISSN 2772-6622. <https://doi.org/10.1016/j.dajour.2023.100327>.
- Kementerian Perdagangan, 2022. Produk Unggulan Indonesia. [online] Pusat Pelatihan Sumber Daya Manusia Ekspor dan Jasa Perdagangan Kementerian Perdagangan. Tersedia di: <<http://ppejp.kemendag.go.id/produk-unggulan-indonesia/>> [Diakses 12 Oktober 2023]
- Knott, M., Perez-Cruz, F., Defraeye, T., 2023. Facilitated machine learning for image-based fruit quality assessment. *Journal of Food Engineering*.
- Matsuzaka, Y., & Yashiro, R., 2023. AI-Based Computer Vision Techniques and Expert Systems. *AI*, 4(1), 289-302.
- Melessea, T.Y., Bollob, M., Pasqualea, V.D., Centrob, F., & Riemma S., 2022. Machine Learning-Based Digital Twin for Monitoring Fruit Quality Evolution. 3rd International Conference on Industry 4.0 and Smart Manufacturing.
- Mundargi, Z., Bhatti, S., Chandra, A., Kamble, A., Jiby, B., & Arole, R. (2023). PrePy - a customize library for data preprocessing in Python. 2023 *International Conference for Advancement in Technology (ICONAT)*. <https://doi.org/10.1109/iconat57137.2023.10080134>
- Novianto, D., & Sugihartono, T., 2020. Sistem Deteksi Kualitas Buah Jambu Air Berdasarkan Warna Kulit Menggunakan Algoritma Principal Component Analysis (Pca) dan K-Nearest Neighbor (K-NN). *Jurnal Ilmiah Informatika Global*, 11(2).
- Papers With Code, tanpa tahun. Max Pooling [online]. Tersedia di: <<https://paperswithcode.com/method/m>

ax-pooling>

- Phung, V. H., & Rhee, E. J., 2019. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences*, 9(21), 4500.
- Podareanu, D., Codreanu, V., van Leeuwen, G. C., & Weinberg, V., 2019. Best practice guide-deep learning. *Partnership for Advanced Computing in Europe (PRACE)*, Tech. Rep, 2.
- Prasetyo, N. A., Surtono, A., Junaidi, J., & Pauzi, G. A., 2021. Sistem Identifikasi Tingkat Kematangan Buah Nanas Secara Non-Destruktif Berbasis Computer Vision. *Journal of Energy, Material, and Instrumentation Technology*, 2(1), 1-10.
- Rajasree, R., Columbus, C.C., & Shilaja, C., 2020. Multiscale-based multimodal image classification of brain tumor using deep learning method. *Neural Computing and Applications*.
- Sasmi, W.T., Sayuti, M., Yulianti, H.T., & Sulastrri, F., 2022. Manfaat Jambu Kristal sebagai Daya Tahan Tubuh di Masa Pandemi COVID-19. Universitas Buana Perjuangan Karawang.
- Sulistiyanti, S.R., Setyawan, F.A., & Komarudin, M., 2016. PENGOLAHAN CITRA; Dasar dan Contoh Penerapannya. TEKNOSAIN: Yogyakarta.
- Wilson, K., 2023. Digital Images, Resolution, and Color Models. In: *Introduction to Photoshop*. Apress, Berkeley, CA. https://doi.org/10.1007/978-1-4842-8963-1_9
- Yanto, B., Rouza, E., Fimawahib, L., Hayadi, B. H., & Pratama, R. R. (2023). Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB). *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(1), 59-66.
- Zou, A., 2023. A survey of convolution. *Second International Conference on Statistics, Applied Mathematics, and Computing Science (CSAMCS 2022)* (Vol. 12597, pp. 966-972). SPIE.