

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI KEMATANGAN BUAH ANGGUR BERBASIS INTERNET OF THINGS (IOT)

Ahmad Zarkasi Fakultas
Ilmu Komputer Universitas
Sriwijaya
Sumatera Selatan, Indonesia

Fazza Putri Desza Fakultas
Ilmu Komputer Universitas
Sriwijaya
Sumatera Selatan, Indonesia

Abstract— Penentuan tingkat kematangan buah anggur secara manual sering kali bersifat subjektif dan tidak konsisten, sehingga dibutuhkan sistem otomatis yang akurat dan efisien. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kematangan buah anggur menggunakan algoritma *Convolutional Neural Network* (CNN) berbasis citra digital. Dataset citra buah anggur dikumpulkan dan diproses melalui teknik augmentasi untuk meningkatkan keragaman data latih. Model CNN dilatih menggunakan data yang telah dibagi menjadi set pelatihan, validasi, dan pengujian, dengan proporsi yang seimbang. Hasil pelatihan menunjukkan bahwa akurasi model pada data pelatihan mencapai 100%, sementara akurasi validasi berkisar antara 73% hingga 77%. Namun, peningkatan nilai loss pada data validasi mengindikasikan kemungkinan overfitting. Evaluasi model dilakukan menggunakan *classification report*, yang menunjukkan performa terbaik pada kelas *stage1* (f1-score 0.99), namun kurang optimal pada kelas *stage4* dan *stage5*. Meskipun demikian, sistem ini memiliki potensi besar untuk diterapkan dalam proses identifikasi kematangan buah anggur secara otomatis dan dapat dikembangkan lebih lanjut dalam integrasi sistem berbasis Internet of Things (IoT) untuk pemantauan waktu nyata.

Keywords— Klasifikasi Kematangan, *Convolutional Neural Network*, Citra Digital, Overfitting, Buah Anggur, IoT.

I. LATAR BELAKANG

Dalam dunia pertanian modern, efisiensi dan ketepatan dalam proses budidaya menjadi tuntutan utama untuk meningkatkan hasil dan mutu produk. Salah satu aspek penting dalam pertanian hortikultura, khususnya pada tanaman buah anggur (*Vitis vinifera*), adalah penentuan tingkat kematangan buah. Penentuan kematangan buah yang akurat sangat memengaruhi kualitas hasil panen, daya simpan, cita rasa, serta nilai jual di pasaran. Kesalahan dalam menentukan waktu panen dapat menyebabkan kerugian ekonomi, baik karena kualitas buah yang kurang optimal maupun karena tingkat kematangan yang tidak sesuai standar distribusi pasar[1], [2].

Selama ini, proses penentuan tingkat kematangan buah anggur umumnya dilakukan secara manual dengan observasi visual berdasarkan perubahan warna kulit buah. Meskipun metode ini cukup umum dan mudah dilakukan, ia memiliki kekurangan dari segi objektivitas dan konsistensi karena

bergantung pada pengalaman serta persepsi masing-masing pengamat[3]. Dalam skala industri atau pertanian berskala besar, pendekatan manual ini kurang efisien dan tidak dapat menjamin akurasi yang tinggi dalam jangka panjang[4].

Seiring dengan perkembangan teknologi, berbagai pendekatan berbasis kecerdasan buatan dan sistem otomatis mulai diterapkan untuk menggantikan metode manual tersebut[5]. Salah satu pendekatan yang menunjukkan hasil menjanjikan adalah penggunaan algoritma *Convolutional Neural Network* (CNN) dalam klasifikasi citra. CNN mampu mengekstraksi fitur visual dari gambar buah dan mengklasifikasikan tingkat kematangannya secara otomatis dan presisi tinggi[6]. Ketika digabungkan dengan teknologi *Internet of Things* (IoT), sistem ini tidak hanya dapat melakukan klasifikasi secara otomatis, tetapi juga memungkinkan proses pemantauan secara *real-time* dari jarak jauh melalui sensor dan kamera yang terhubung ke jaringan[7].

Penggunaan CNN dan IoT dalam sistem klasifikasi kematangan buah anggur diharapkan mampu memberikan solusi cerdas yang efisien dan efektif. [8]Sistem ini tidak hanya bermanfaat untuk petani, tetapi juga dapat diterapkan pada proses pasca-panen, distribusi, hingga *quality control* di industri pengolahan makanan. Oleh karena itu, penelitian ini mengembangkan sebuah sistem klasifikasi kematangan buah anggur berbasis CNN dan IoT dengan tujuan untuk membantu proses identifikasi tingkat kematangan secara otomatis, akurat, dan *real-time*, serta menjadi alternatif modern dari metode manual yang selama ini digunakan[9].

Penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem klasifikasi kematangan buah anggur secara otomatis dengan memanfaatkan algoritma *Convolutional Neural Network* (CNN) dan teknologi *Internet of Things* (IoT). Sistem ini diharapkan mampu melakukan identifikasi tingkat kematangan buah secara cepat, akurat, dan *real-time*, serta dapat membantu petani maupun pelaku industri dalam mengambil keputusan panen yang lebih tepat. Dengan pendekatan berbasis teknologi ini, proses klasifikasi yang sebelumnya bersifat subjektif dan manual dapat ditingkatkan menjadi sistematis dan terstandarisasi, sehingga berkontribusi pada efisiensi operasional dan peningkatan kualitas hasil panen anggur secara keseluruhan.

II. METODOLOGI PENELITIAN

A. Sumber data

Data penelitian diperoleh dari Roboflow dalam format anotasi gambar yang telah diklasifikasikan ke dalam empat kelas kematangan anggur, yaitu *stage1*, *stage2*, *stage4*, dan *stage5*. Dataset ini dibagi menjadi tiga subset: training, validation, dan testing. Sebelum dilatih dengan model CNN, data melalui tahap preprocessing yang meliputi resizing gambar ke resolusi yang seragam, normalisasi piksel, serta augmentasi seperti rotasi, flipping, dan perubahan *brightness* untuk meningkatkan generalisasi model[10]. Proses ini bertujuan meminimalkan overfitting dan meningkatkan performa klasifikasi pada data pengujian.

B. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah algoritma deep learning yang digunakan untuk mengenali dan mengklasifikasikan pola dalam gambar. CNN bekerja dengan memproses gambar melalui lapisan-lapisan convolution, aktivasi, dan pooling untuk mengekstraksi ciri visual seperti warna, bentuk, dan tekstur[11][12].

Pada penelitian ini, CNN dirancang menggunakan tiga lapisan convolutional dengan jumlah filter yang meningkat secara bertahap (16, 32, dan 64)[13]. Setiap lapisan convolution diikuti oleh fungsi aktivasi ReLU dan pooling untuk menyaring fitur penting sekaligus mengurangi dimensi data[14]. Hasil ekstraksi fitur kemudian diratakan (flatten)

dan diproses oleh dua lapisan fully connected, yang pada akhirnya menghasilkan prediksi kelas kematangan buah anggur melalui fungsi aktivasi akhir.

C. Perancangan sistem

Perancangan sistem yang digunakan pada penelitian ini terdiri dari tahapan deteksi dan klasifikasi tingkat kematangan buah anggur. Proses diawali dengan akuisisi gambar RGB, dilanjutkan dengan ekstraksi fitur seperti warna, ukuran, dan tekstur[15]. Selanjutnya, fitur dikonversi menjadi vektor dan diproses menggunakan algoritma Convolutional Neural Network (CNN) untuk mengklasifikasikan kematangan anggur ke dalam tiga kelas, yaitu belum matang, setengah matang, dan matang.




Figure 1. Perancangan sistem

D. Preprocessing

Untuk meningkatkan jumlah data dan memperkaya variasi visual pada dataset, dilakukan proses data augmentation. Proses ini menciptakan citra baru dari citra asli melalui transformasi seperti rotasi, flipping horizontal, zoom, dan *brightness adjustment*[9].




figure 2 data augmentasi

Figure 2 .Data augmentation menunjukkan perbandingan antara citra asli dan hasil augmentasi dari keempat kelas kematangan buah anggur (*stage1*, *stage2*, *stage4*, dan *stage5*).Dapat dilihat bahwa meskipun terjadi transformasi, struktur utama objek tetap terlihat dan representasi kelas tetap relevan.Data augmentasi ini bertujuan untuk meningkatkan generalisasi model dan mengurangi risiko overfitting, terutama karena dataset awal memiliki jumlah data yang relatif terbatas per kelas.

E. Arsitektur dan Pelatihan Model CNN

Model *Convolutional Neural Network* (CNN) yang digunakan dalam penelitian ini dirancang dengan arsitektur berlapis untuk mengekstraksi ciri visual dari citra buah anggur dan melakukan klasifikasi ke dalam empat kelas kematangan, yaitu *stage1*, *stage2*, *stage4*, dan *stage5*. Arsitektur model terdiri dari tiga lapisan konvolusi (Conv2D) berturut-turut, masing-masing dengan jumlah filter sebanyak 16, 32, dan 64 serta ukuran kernel 3x3. Setiap lapisan konvolusi diikuti oleh fungsi aktivasi *Rectified Linear Unit* (ReLU) dan *max pooling* dengan ukuran 2x2 untuk mengurangi dimensi spasial dan menyaring fitur penting dari gambar.

Setelah ekstraksi fitur selesai, data diratakan menggunakan *Flatten*, lalu diproses oleh dua lapisan *fully connected* (Dense). Lapisan pertama terdiri dari 128 neuron dengan aktivasi ReLU, dan lapisan terakhir menggunakan softmax sebagai fungsi aktivasi untuk menghasilkan output klasifikasi ke empat kelas. Model dibangun menggunakan framework Keras dengan API Sequential. Berikut merupakan ringkasan arsitektur model CNN yang digunakan:

Layer (type)	Output Shape	Param #
Conv2d-1	[-1, 32, 180, 180]	896
ReLU-2	[-1, 32, 180, 180]	0
MaxPool2d-3	[-1, 32, 90, 90]	0
Conv2d-4	[-1, 64, 90, 90]	18,496
ReLU-5	[-1, 64, 90, 90]	0
MaxPool2d-6	[-1, 64, 45, 45]	0
Conv2d-7	[-1, 128, 45, 45]	73,856
ReLU-8	[-1, 128, 45, 45]	0
MaxPool2d-9	[-1, 128, 22, 22]	0
Flatten-10	[-1, 61952]	0
Linear-11	[-1, 256]	15,859,968
ReLU-12	[-1, 256]	0
Linear-13	[-1, 4]	1,028
Total params: 15,954,244		
Trainable params: 15,954,244		
Non-trainable params: 0		
Input size (MB): 0.37		
Forward/backward pass size (MB): 31.60		
Params size (MB): 60.86		
Estimated Total Size (MB): 92.83		

figure 3 Model CNN

Model dikompilasi menggunakan optimizer Adam dengan *loss function categorical_crossentropy*, karena klasifikasi yang dilakukan bersifat multi-kelas. Proses pelatihan dilakukan selama 10 epoch dengan ukuran batch sebanyak 32, menggunakan data yang telah dibagi sebelumnya menjadi data latih (80%) dan data uji (20%). Selama proses pelatihan, nilai *loss* dan *accuracy* dicatat untuk mengevaluasi kinerja model terhadap data latih maupun data validasi.




Figure 4 Data Training dan Validation

Grafik menunjukkan bahwa model mengalami penurunan nilai *loss* secara konsisten dan peningkatan akurasi validasi, yang menandakan bahwa model mampu mempelajari pola secara efektif tanpa overfitting dalam jumlah epoch yang digunakan.

III. HASIL ANALISIS

A. Tahap Pre-Processing

Model CNN dilatih menggunakan dataset gambar buah anggur yang telah melalui proses preprocessing dan augmentasi. Proses pelatihan dilakukan selama 10 epoch dengan ukuran batch sebesar 32, menggunakan optimizer Adam dan *loss function categorical_crossentropy*. Selama proses pelatihan, sistem mencatat nilai *loss* dan *accuracy* pada data latih maupun data validasi untuk memantau perkembangan performa model.

	Epoch	Train Loss	Train Accuracy	Val Loss	Val Accuracy
0	1	0.1796	93.05%	0.4357	84.07%
1	2	0.1313	95.27%	0.4701	83.39%
2	3	0.1149	95.95%	0.5201	83.73%
3	4	0.0981	97.1%	0.5782	83.39%
4	5	0.0735	97.59%	0.6589	80.34%
5	6	0.0550	98.36%	0.6956	83.39%
6	7	0.0770	97.39%	0.6055	82.71%
7	8	0.0606	98.26%	0.8371	79.66%
8	9	0.0751	96.81%	0.8780	77.97%
9	10	0.0590	97.97%	0.7151	83.73%

Figure 5 Data Hasil Training dan Validation Berdasarkan

grafik pelatihan, nilai *training loss* menunjukkan penurunan secara konsisten dari epoch ke epoch, dimulai dari nilai sekitar 1.2 dan menurun hingga mencapai sekitar 0.25 pada epoch ke-10. Hal ini menunjukkan bahwa model berhasil mempelajari fitur dari data latih dengan baik.

Sementara itu, *validation accuracy* meningkat dari sekitar 69% pada epoch pertama menjadi sekitar 84% pada epoch ke-10. Kenaikan ini menunjukkan bahwa model tidak hanya belajar dari data latih, tetapi juga mampu melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya. Tren ini mengindikasikan bahwa proses pelatihan berjalan stabil dan tidak terjadi overfitting dalam jumlah epoch yang digunakan. Dengan demikian, model

CNN yang dibangun dinyatakan cukup baik dan layak untuk dievaluasi lebih lanjut menggunakan data uji.

B. Analisis Model CNN

Setelah proses pelatihan selesai, model CNN diuji menggunakan data uji yang sebelumnya telah dipisahkan sebanyak 20% dari total dataset. Evaluasi ini bertujuan untuk mengukur sejauh mana model mampu mengklasifikasikan tingkat kematangan buah anggur ke dalam empat kelas, yaitu *stage1*, *stage2*, *stage4*, dan *stage5*.




Figure 6 Confusion Matrix

Hasil pengujian divisualisasikan dalam bentuk confusion matrix, yang memperlihatkan distribusi prediksi model terhadap label sebenarnya. Berdasarkan hasil tersebut, model menunjukkan performa yang sangat baik dalam mengklasifikasikan kelas *stage1* dan *stage2*, dengan jumlah prediksi benar yang tinggi dan kesalahan yang sangat minim. Namun, pada kelas *stage4* dan *stage5*, terjadi kesalahan klasifikasi yang cukup signifikan di mana keduanya sering saling tertukar. Hal ini mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan dua tingkat kematangan akhir yang memiliki karakteristik visual yang sangat mirip, baik dari segi warna maupun tekstur buah.

Classification Report:

	precision	recall	f1-score	support
stage1	1.00	1.00	1.00	38
stage2	1.00	0.90	0.95	40
stage4	0.57	0.61	0.59	28
stage5	0.75	0.79	0.77	42
accuracy			0.84	148
macro avg	0.83	0.82	0.83	148
weighted avg	0.85	0.84	0.84	148

figure 7. Classification Report

Untuk memperoleh evaluasi yang lebih komprehensif, digunakan pula *classification report* yang menyajikan metrik evaluasi berupa *precision*, *recall*, dan *f1-score* untuk masing-masing kelas. Kelas *stage1* menunjukkan performa terbaik dengan *precision* dan *recall* sebesar 1.00, menandakan bahwa seluruh prediksi untuk kelas ini benar dan tidak ada kesalahan klasifikasi. Kelas *stage2* juga menunjukkan hasil yang sangat baik dengan *f1-score* di atas 0.90.

Sementara itu, kelas *stage4* memperoleh *f1-score* terendah, yaitu 0.59, yang mengindikasikan bahwa model sering keliru dalam mengidentifikasi kelas ini. Kelas *stage5* menunjukkan kinerja yang lebih baik dibanding *stage4*, dengan *f1-score* sebesar 0.77. Secara keseluruhan, model CNN yang dikembangkan berhasil mencapai akurasi total sebesar 84%, dan *macro average f1-score* sebesar 0.83. Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dan seimbang dalam mengklasifikasikan citra buah anggur ke dalam empat kelas kematangan, meskipun masih diperlukan peningkatan akurasi pada kelas dengan kemiripan visual yang tinggi.

C. Visualisasi Hasil Prediksi Model CNN

Untuk memberikan gambaran lebih jelas mengenai kemampuan model dalam mengklasifikasikan tingkat kematangan buah anggur, dilakukan visualisasi terhadap hasil prediksi pada data uji. Visualisasi ini menampilkan beberapa contoh citra uji beserta label sebenarnya (*true label*), hasil prediksi model (*predicted label*), dan tingkat kepercayaan (*confidence score*) dari prediksi tersebut.



Figure 8. Prediction Examples

Beberapa hasil visualisasi menunjukkan bahwa model mampu mengidentifikasi kelas *stage1* dan *stage2* dengan tingkat akurasi dan keyakinan yang tinggi. Sebagai contoh, citra buah anggur yang termasuk dalam kelas *stage2* diprediksi dengan benar oleh model dengan tingkat kepercayaan mencapai 98%.

Namun demikian, pada beberapa citra uji lain, terutama yang termasuk dalam kelas *stage4* dan *stage5*, terdapat kasus di mana prediksi model tidak sesuai dengan label sebenarnya. Hal ini terjadi kemungkinan karena kemiripan visual antara kedua kelas tersebut, yang menyebabkan model mengalami kebingungan dalam membedakannya. Selain itu, dalam beberapa prediksi yang salah, nilai *confidence score* model

juga lebih rendah, yang mengindikasikan ketidakpastian dalam proses klasifikasi.

Visualisasi ini memperkuat hasil evaluasi sebelumnya, di mana model bekerja sangat baik untuk kelas awal kematangan (*stage1* dan *stage2*), namun masih membutuhkan peningkatan pada klasifikasi kelas yang lebih kompleks dan mirip secara visual.

D. Pembahasan hasil

Model *Convolutional Neural Network* (CNN) yang dikembangkan dalam penelitian ini menunjukkan performa yang cukup baik dalam tugas klasifikasi tingkat kematangan buah anggur ke dalam empat kelas, yaitu *stage1*, *stage2*, *stage4*, dan *stage5*. Hasil evaluasi yang diperoleh dari data uji menunjukkan bahwa model berhasil mencapai akurasi sebesar 84% dengan *macro average F1-score* sebesar 0.83. Nilai-nilai tersebut mencerminkan bahwa model memiliki kemampuan yang cukup seimbang dalam mengklasifikasikan data antar kelas secara umum.

Kinerja model paling optimal ditunjukkan pada dua kelas awal, yaitu *stage1* dan *stage2*. Berdasarkan hasil *classification report* dan *confusion matrix*, kelas ini memiliki nilai *precision* dan *recall* yang sangat tinggi, bahkan mencapai 1.00 pada kelas *stage1*. Hal ini dapat dijelaskan dari segi karakteristik visual, di mana buah anggur pada tahap kematangan awal cenderung memiliki perbedaan warna yang mencolok, seperti hijau muda atau kekuningan, serta tekstur permukaan yang masih kencang dan belum banyak perubahan. Dengan ciri yang lebih kontras seperti ini, model CNN dapat lebih mudah menangkap fitur-fitur penting melalui proses ekstraksi fitur pada lapisan *convolutional*.

Sebaliknya, performa model mulai menurun pada kelas *stage4* dan *stage5*. Kedua kelas ini memiliki *F1-score* yang lebih rendah, masing-masing sekitar 0.59 untuk *stage4* dan 0.77 untuk *stage5*.

Kesalahan klasifikasi paling sering terjadi antara kedua kelas ini, yang saling bertukar satu sama lain. Fenomena ini terjadi karena buah anggur pada tahap kematangan akhir memiliki warna yang hampir seragam (biasanya ungu tua hingga kehitaman), serta tekstur permukaan yang cenderung serupa. Dalam konteks visual, fitur-fitur seperti warna dan bentuk sudah tidak lagi cukup kuat untuk membedakan keduanya secara konsisten. Akibatnya, model mengalami kesulitan dalam mengenali perbedaan yang sangat halus ini, terutama jika data pelatihan yang tersedia untuk kedua kelas tersebut jumlahnya terbatas atau tidak cukup bervariasi.

Visualisasi hasil prediksi juga menguatkan temuan ini. Gambar-gambar uji yang termasuk dalam kelas *stage1* dan *stage2* umumnya diprediksi dengan *confidence score* tinggi di atas 90%, menandakan bahwa model sangat yakin terhadap klasifikasi tersebut. Sementara itu, pada citra *stage4* dan *stage5*, terdapat beberapa prediksi yang salah dan *confidence score*-nya rendah (di bawah 75%). Hal ini menandakan bahwa model merasa “tidak yakin” terhadap keputusan klasifikasi pada gambar-gambar dengan kemiripan tinggi tersebut.

Secara teknis, kesulitan dalam membedakan kelas dengan fitur visual yang mirip merupakan tantangan umum dalam penerapan CNN pada klasifikasi citra multi-kelas. Selain itu, kualitas data dan keseimbangan jumlah data antar kelas sangat mempengaruhi proses pembelajaran model. Dalam kasus ini, kemungkinan besar data pelatihan pada kelas *stage4* dan *stage5* masih kurang representatif secara visual atau terlalu seragam, sehingga model gagal mempelajari variasi yang diperlukan. Melihat hal tersebut, diperlukan beberapa strategi pengembangan lanjutan agar akurasi klasifikasi pada seluruh kelas dapat ditingkatkan secara merata. Beberapa pendekatan yang dapat dilakukan antara lain:

- Penambahan jumlah data pelatihan, khususnya pada kelas *stage4* dan *stage5*, untuk meningkatkan representasi variasi visual dari kelas-kelas tersebut.
- Augmentasi lanjutan secara selektif, seperti penyesuaian kontras, pengaburan (*blurring*), atau simulasi kondisi pencahayaan berbeda agar model dapat belajar mengenali fitur lebih dalam dari aspek warna dan tekstur.
- Peningkatan arsitektur model CNN, misalnya dengan menggunakan arsitektur *pre-trained* seperti *ResNet*, *MobileNet*, atau *EfficientNet* melalui pendekatan *transfer learning*, yang terbukti lebih kuat dalam menangani data visual kompleks.
- Integrasi data sensor tambahan dalam konteks *Internet of Things* (IoT), seperti penggunaan sensor warna spektrum atau suhu, untuk membantu meningkatkan akurasi klasifikasi dengan pendekatan *multimodal*.

Dengan strategi-strategi tersebut, model yang dikembangkan dapat ditingkatkan tidak hanya dari sisi performa klasifikasi, tetapi juga dari segi ketahanan dan akurasi saat diterapkan di kondisi nyata, seperti pada sistem pemanenan otomatis, monitoring pertanian berbasis IoT, atau aplikasi klasifikasi kematangan berbasis kamera *real-time*.

IV. KESIMPULAN DAN SARAN

Penelitian ini bertujuan untuk mengembangkan sebuah sistem klasifikasi kematangan buah anggur berbasis *Convolutional Neural Network* (CNN) yang dapat diimplementasikan dalam konteks *Internet of Things* (IoT). Berdasarkan hasil implementasi dan evaluasi, dapat disimpulkan bahwa model CNN yang dibangun dengan arsitektur tiga lapisan *convolutional* dan dua lapisan *fully connected* menunjukkan performa klasifikasi yang cukup baik. Model ini dilatih menggunakan dataset citra buah anggur yang diperoleh dari Roboflow, yang telah melalui proses *preprocessing* meliputi *resizing*, *normalisasi piksel*, serta *augmentasi data* seperti *rotasi*, *flipping*, dan pengaturan *brightness* untuk memperkaya variasi citra pelatihan. Proses *preprocessing* ini terbukti efektif dalam meningkatkan kemampuan generalisasi model terhadap data uji yang sebelumnya tidak pernah dilihat.

Hasil pengujian model menunjukkan bahwa CNN mampu mengklasifikasikan tingkat kematangan buah anggur ke dalam empat kelas, yaitu *stage1*, *stage2*, *stage4*, dan *stage5*, dengan tingkat akurasi mencapai 84% dan nilai *macro average F1-score* sebesar 0.83. Evaluasi lebih lanjut melalui confusion matrix dan classification report menunjukkan bahwa model bekerja sangat baik dalam mengenali buah anggur pada tahap kematangan awal, khususnya *stage1* dan *stage2*, dengan precision dan recall yang sangat tinggi bahkan mencapai nilai sempurna pada *stage1*. Hal ini menunjukkan bahwa karakteristik visual pada tahap awal, seperti warna cerah dan tekstur yang jelas, lebih mudah dikenali oleh CNN.

Namun, tantangan masih muncul pada proses klasifikasi tingkat kematangan akhir, yaitu pada kelas *stage4* dan *stage5*. Meskipun keduanya termasuk ke dalam kategori matang, kemiripan visual seperti warna gelap dan tekstur permukaan yang hampir seragam membuat model kesulitan dalam membedakan keduanya. Hal ini tercermin dalam rendahnya nilai *f1-score* pada kelas *stage4*, serta adanya kesalahan klasifikasi yang cukup sering ditemukan di antara dua kelas tersebut. Visualisasi hasil prediksi memperkuat hal ini, di mana model menunjukkan tingkat kepercayaan (*confidence score*) yang tinggi saat memprediksi kelas awal, namun menjadi lebih rendah dan ragu saat menghadapi citra dari kelas akhir yang lebih sulit dibedakan.

Berdasarkan temuan ini, dapat disimpulkan bahwa CNN merupakan pendekatan yang potensial dan efisien dalam tugas klasifikasi visual tingkat kematangan buah, terutama ketika fitur-fitur visual seperti warna dan tekstur cukup kontras antar kelas. Namun demikian, untuk mencapai hasil yang lebih stabil dan akurat pada seluruh kelas, perlu dilakukan sejumlah pengembangan. Salah satunya adalah dengan memperluas dataset, khususnya pada kelas yang performanya masih rendah, agar model dapat belajar dari variasi visual yang lebih kaya. Di samping itu, penerapan teknik augmentasi lanjutan dan penggunaan model pre-trained (*transfer learning*) seperti MobileNet atau ResNet dapat menjadi strategi yang efektif untuk meningkatkan kemampuan generalisasi, terutama dalam situasi dengan keterbatasan data. Integrasi dengan sensor tambahan berbasis IoT seperti sensor warna atau sensor suhu juga bisa menjadi solusi untuk menciptakan sistem klasifikasi multimodal yang lebih cerdas dan responsif.

Secara keseluruhan, sistem yang dikembangkan dalam penelitian ini telah berhasil menunjukkan bahwa CNN dapat digunakan secara efektif untuk mengenali kematangan buah anggur berdasarkan citra visual. Ke depan, sistem ini sangat berpotensi untuk diterapkan dalam aplikasi pertanian presisi berbasis IoT, seperti pemanenan otomatis, monitoring tanaman, atau sistem klasifikasi buah real-time berbasis kamera. Dengan pengembangan lebih lanjut, diharapkan sistem ini dapat membantu meningkatkan efisiensi dan akurasi dalam proses pascapanen maupun pengambilan keputusan di bidang pertanian modern.

REFERENCES

- [1] J. S. Mommoh, J. L. Obeta, S. N. John, K. Okokpujie, O. N. Omoruyi, and A. A. Awelewa, "Detection of Fruit Ripeness and Defectiveness Using Convolutional Neural Networks," *Information Dynamics and Applications*, vol. 3, no. 3, pp. 184–199, Sep. 2024, doi: 10.56578/ida030304.
- [2] U. Amin, M. I. Shahzad, A. Shahzad, M. Shahzad, U. Khan, and Z. Mahmood, "Automatic Fruits Freshness Classification Using CNN and Transfer Learning," *Applied Sciences (Switzerland)*, vol. 13, no. 14, Jul. 2023, doi: 10.3390/app13148087.
- [3] F. Xiao, H. Wang, Y. Xu, and R. Zhang, "Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review," Jun. 01, 2023, *MDPI*. doi: 10.3390/agronomy13061625.
- [4] H. Herman, A. Susanto, T. Wawan Cenggoro, and B. Pardamean, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," 2020, [Online]. Available: https://farm3.static.flickr.com/2337/2387965665_1d4278c6
- [5] E. Tapia-Mendez, I. A. Cruz-Albarran, S. Tovar- Arriaga, and L. A. Morales-Hernandez, "Deep Learning-Based Method for Classification and Ripeness Assessment of Fruits and Vegetables," *Applied Sciences (Switzerland)*, vol. 13, no. 22, Nov. 2023, doi: 10.3390/app132212504.
- [6] F. B. Setiawan, C. B. Adipradana, and L. H. Pratomo, "Fruit Ripeness Classification System Using Convolutional Neural Network (CNN) Method," *PROtek : Jurnal Ilmiah Teknik Elektro*, vol. 10, no. 1, p. 46, Jan. 2023, doi: 10.33387/protk.v10i1.5549.
- [7] D. Iskandar Mulyana, A. Akbar, M. Zikri, T. Informatika, and S. Cipta Karya Informatika, "Optimasi Klasifikasi Buah Anggur Menggunakan Data Augmentasi dan Convolutional Neural Network," vol. 11, no. 2, 2022.
- [8] "IRFADIANA NURHASANAH D121 18 1501 PROGRAM STUDI SARJANA TEKNIK INFORMATIKA FAKULTAS TEKNIK UNIVERSITAS HASANUDDIN GOWA 2023."
- [9] K. O. Borromeo, M. R. Bonotan, A. P. Llagas, J. M. O. Juan, P. D. C. Sanchez, and N. K. A. Berro, "Classification of Cacao Pods Ripeness Using Convolutional Neural Networks," in *Procedia Computer Science*, Elsevier B.V., 2025, pp. 1197– 1204. doi: 10.1016/j.procs.2025.03.160.
- [10] N. Ismail and O. A. Malik, "Real-time visual inspection system for grading fruits using computer vision and deep learning techniques," *Information Processing in Agriculture*, vol. 9, no. 1, pp. 24–37, Mar. 2022, doi: 10.1016/j.inpa.2021.01.005.
- [11] Y. Yuan, L. Chen, H. Wu, and L. Li, "Advanced agricultural disease image recognition technologies: A review," Mar. 01, 2022, *China Agricultural University*. doi: 10.1016/j.inpa.2021.01.003.

-
- [12] M. Ali Nur Hidayat, "Convolutional Neural Network Pada Identifikasi Varian Tanaman Anggur Menggunakan Resnet-50," vol. 10, no. 3, pp. 61–70, 2023, [Online]. Available: <http://jurnal.mdp.ac.id>
- [13] Anissa Ollivia Cahya Pratiwi, "Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan Convolutional Neural Network Dan K-Nearest Neighbor," *Jurnal Ilmiah Teknik Informatika dan Komunikasi*, vol. 3, no. 2, pp. 201–224, Jul. 2023, doi: 10.55606/juitik.v3i2.535.
- [14] Moh. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 4, pp. 218–223, Oct. 2021, doi: 10.14710/jtsiskom.2021.14013.
- [15] D. Mirwansyah and Arief Wibowo, "FRUIT IMAGE CLASSIFICATION USING DEEP LEARNING ALGORITHM: SYSTEMATIC LITERATURE REVIEW (SLR)," *MULTICA SCIENCE AND TECHNOLOGY (MST) JOURNAL*, vol. 2, no. 2, pp. 120–123, Oct. 2022, doi: 10.47002/mst.v2i2.356.