

Aplikasi CNN untuk Analisis Visual Pertumbuhan Tanaman Bitter Melon dalam Sistem Akuaponik

Rapli Wijaya¹, Yurni Oktarina¹, Tresna Dewi¹, Pola Risma¹

¹Jurusan Teknik Elektro
Politeknik Negeri Sriwijaya
Palembang, Indonesia

corresponding author(s): yurni_oktarina@polsri.ac.id

Abstrak— Perkembangan teknologi kecerdasan buatan telah membuka peluang besar dalam modernisasi sektor pertanian, salah satunya melalui sistem budidaya akuaponik. Penelitian ini merancang sistem klasifikasi otomatis menggunakan metode Convolutional Neural Network (CNN) yang dikombinasikan dengan pendekatan transfer learning berbasis model ResNet50, fungsinya untuk mengidentifikasi kondisi tanaman pare (bitter melon) dalam lingkungan akuaponik. Dataset yang digunakan mencakup dua kategori utama, yaitu Good Condition dan Reject, dengan citra yang diperoleh dari kamera beresolusi tinggi dan dibagi ke dalam data latih serta uji. Model ResNet50 memperlihatkan performa tinggi pada data pelatihan dengan nilai presisi 0,92, recall 1,00, dan F1-score 0,96. Namun, kemampuan generalisasi model terhadap data uji masih rendah, yang mengindikasikan kemungkinan terjadinya overfitting. Di sisi lain, model CNN memberikan hasil akurasi sempurna pada data pengujian, meskipun validitas hasil ini masih terbatas oleh jumlah data uji yang minim. Untuk memperkaya keragaman data, dilakukan teknik augmentasi berupa rotasi, pembalikan, dan perbesaran gambar. Temuan ini menunjukkan bahwa pendekatan berbasis deep learning memiliki potensi besar dalam mendukung sistem pemantauan pertumbuhan tanaman yang cerdas dan adaptif, khususnya dalam lingkungan akuaponik.

Kata Kunci—CNN, *transfer learning*, ResNet50, *bitter melon*, akuaponik, klasifikasi citra.

Abstract—The development of artificial intelligence technology has opened up great opportunities in modernizing the agricultural sector, one of which is through aquaponic cultivation systems. This research designs an automatic classification system using the Convolutional Neural Network (CNN) method combined with a transfer learning approach based on the ResNet50 model, its function is to identify the condition of bitter melon plants in an aquaponic environment. The dataset used includes two main categories, Good Condition and Reject, with images obtained from high-resolution cameras and divided into training and test data. The ResNet50 model showed high performance on the training data with a precision of 0.92, recall of 1.00, and F1-score of 0.96. However, the generalization ability of the model to the test data was low, indicating the possibility of overfitting. On the other hand, the CNN model provides perfect accuracy results on the test data, although the validity of these results is still limited by the minimal amount of test data. To enrich the diversity of the data, augmentation techniques such as rotation, inversion, and magnification of the images were performed. These findings show that deep learning-based approaches have great potential in supporting intelligent and adaptive plant growth monitoring systems, especially in aquaponic environments.

Keywords—CNN, *transfer learning*, ResNet50, *bitter melon*, *aquaponics*, *image classification*.

I. PENDAHULUAN

Pemanfaatan teknologi berbasis kecerdasan buatan dalam sektor pertanian semakin berkembang pesat. Salah satu teknik yang banyak diterapkan adalah pengolahan citra berbasis CNN untuk analisis serta klasifikasi tanaman [1]. Dalam sistem akuaponik, pemantauan kondisi tanaman secara visual menjadi elemen penting untuk mempertahankan produktivitas. Dengan dukungan teknologi deep learning, proses identifikasi kondisi tanaman dapat dilakukan secara lebih efisien, memungkinkan deteksi dini terhadap pertumbuhan yang tidak optimal [2].

Bitter melon merupakan tanaman bernilai ekonomi tinggi yang sering dibudidayakan dalam sistem akuaponik [3]. Namun, tantangan utama dalam budidayanya adalah memastikan kualitas pertumbuhan tanaman tetap optimal. Oleh karena itu, sistem otomatis berbasis CNN dibutuhkan untuk mengklasifikasikan kondisi tanaman dengan tingkat akurasi yang tinggi [4].

Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis CNN dengan pendekatan transfer learning menggunakan ResNet50 guna mengelompokkan tanaman bitter melon ke dalam dua kategori, yakni Good Condition dan Reject. CNN telah diterapkan secara luas dalam pengelompokan gambar tumbuhan dengan berbagai metode pemindahan pembelajaran yang terbukti efektif dalam meningkatkan ketepatan model [5]. Dataset diperoleh

dari citra yang diambil menggunakan kamera smartphone iPhone 15 yang memiliki resolusi 48 MP dan selanjutnya diproses untuk melatih model klasifikasi [6]. Model yang dirancang diharapkan mampu berfungsi sebagai jawaban untuk sistem pemantauan pertumbuhan tanaman secara otomatis di dalam ekosistem akuaponik. Selain itu, ini juga dapat menjadi titik awal dalam kemajuan teknologi yang mengandalkan kecerdasan buatan dalam sektor pertanian presisi [7].

Model ResNet50 menunjukkan hasil yang sangat baik pada tahap pelatihan, dengan presisi mencapai 92%, recall 100%, dan nilai F1-score sebesar 96%. Namun, performa model menurun drastis ketika diterapkan pada data uji, yang mengindikasikan potensi terjadinya overfitting. Di sisi lain, model CNN sederhana justru memberikan hasil yang sempurna pada data uji, meskipun keandalannya masih perlu dibuktikan lebih lanjut karena terbatasnya jumlah data pengujian.

Hasil penelitian ini menunjukkan bahwa penerapan CNN dan *transfer learning* dalam klasifikasi tanaman pare memiliki potensi besar untuk mendukung sistem pemantauan otomatis berbasis visual dalam ekosistem akuaponik.

II. TINJAUAN PUSTAKA

A. Penelitian *Terkait*

Beberapa hasil studi sebelumnya menjadi bahan kajian yang dijadikan referensi dalam penelitian ini serta sebagai landasan untuk menambahkan inovasi. Referensi pertama adalah kajian yang mengupas penerapan CNN dalam klasifikasi tanaman dan analisis pertumbuhan tanaman melalui citra. Nugroho dan Supatman [8] menciptakan model CNN untuk mendeteksi salak yang terinfeksi larva dengan tingkat akurasi yang tinggi. Hal ini menegaskan efektivitas metode CNN dalam klasifikasi objek yang berbasis citra. Yuliany et al. [9] juga menggunakan deep learning untuk mengklasifikasikan hama pada tanaman padi, yang dapat memberikan bantuan kepada petani dalam mengenali serangga hama dengan lebih cepat dan tepat.

Selanjutnya, penelitian yang dilakukan oleh Nashrullah et al. [10] meninjau pengaruh dari parameter epoch terhadap struktur ResNet50 dalam klasifikasi gambar, yang menjadi salah satu aspek yang dipikirkan dalam pemilihan model dalam kajian ini. Di samping itu, studi oleh Oktafanda [11] yang mengembangkan sistem untuk klasifikasi bibit kelapa sawit melalui CNN memperlihatkan bahwa metode tersebut dapat meningkatkan efisiensi dalam pemilihan bibit yang berkualitas.

Rujukan kedua terkait dengan penggunaan teknologi IoT dalam pengawasan pertumbuhan tanaman. Studi yang dilakukan oleh Saputra et al. [12] mengembangkan sistem untuk mengklasifikasikan kesehatan tanaman padi dengan menggunakan citra UAV yang didukung oleh CNN, yang memungkinkan pemantauan otomatis kondisi tanaman dalam konteks pertanian presisi. Ini sejalan dengan tujuan penelitian ini untuk menciptakan sistem klasifikasi visual pertumbuhan bitter melon dalam kerangka kerja akuaponik.

Selanjutnya, penelitian oleh Jinan et al. [13] membuktikan bahwa CNN efektif untuk mengklasifikasikan penyakit pada tanaman padi melalui citra daun. Model CNN terbukti dapat mendeteksi tanda-tanda penyakit dalam tahap awal, sehingga memungkinkan untuk melakukan langkah-langkah pencegahan yang cepat. Metode yang diterapkan dalam studi ini juga digunakan untuk mengklasifikasikan tanaman bitter melon dengan tujuan mendeteksi pertumbuhan yang kurang optimal.

Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa pemanfaatan Deep Learning model CNN untuk klasifikasi tanaman melalui citra berpotensi besar dalam meningkatkan efisiensi pemantauan dan analisis pertumbuhan tanaman secara otomatis. Penelitian ini mengembangkan pendekatan yang lebih terfokus dengan memanfaatkan deep learning pada model CNN untuk meningkatkan akurasi dalam mengklasifikasikan kondisi tanaman bitter melon dalam sistem akuaponik.

B. Peran Citra Digital Dalam Pemantauan Tanaman

Penggunaan gambar digital dalam sistem akuaponik memungkinkan pemantauan otomatis terhadap pertumbuhan tanaman. Gambar tanaman yang diambil melalui kamera CCTV atau alat pemantauan lain dapat dianalisis dengan teknik pembelajaran mendalam, seperti CNN, untuk mengenali kondisi tanaman berdasarkan tampilan visualnya [14].

Perubahan dalam faktor lingkungan seperti pencahayaan, kelembapan, dan nutrisi dalam air dapat mempengaruhi kualitas gambar yang dihasilkan. Untuk itu, metode augmentasi data seperti rotasi, penyesuaian kontras, dan pembalikan diterapkan guna meningkatkan ketahanan model terhadap variasi yang ada dalam dataset [15].

C. Implementasi CNN dalam Klasifikasi Tanaman

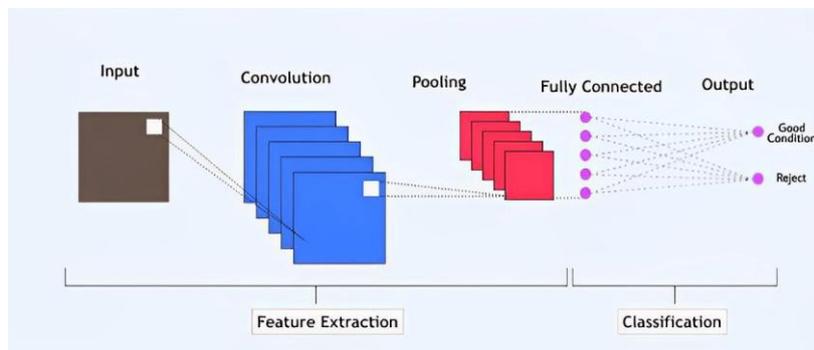
CNN telah banyak diperdagangkan dalam pengelompokan tanaman berdasar atribut morfologi serta warna daun ataupun buah. Pada studi ini, model CNN digunakan untuk menarik fitur visual dari gambar tanaman pare dengan tujuan mengidentifikasi kondisi pertumbuhannya [16].

Struktur CNN dipilih karena kemampuan luar biasanya dalam menangani masalah gradien yang menghilang yang kerap terjadi dalam jaringan saraf konvolusional dengan banyak lapisan. Dengan menerapkan model ini dapat menggunakan bobot yang berasal dari pelatihan sebelumnya, yang mempercepat proses konvergensi dan meningkatkan ketepatan klasifikasi [17].

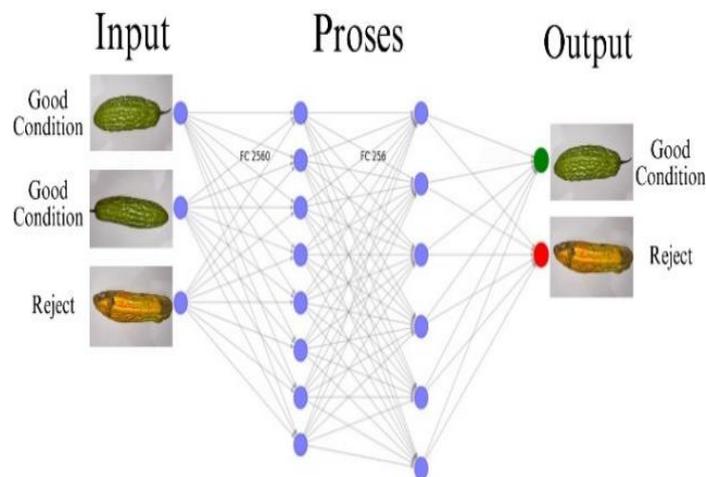
III. METODE PENELITIAN

Penelitian ini menggunakan CNN dan transfer learning model ResNet50 untuk mengklasifikasikan status buah *bitter melon* (Pare) ke dalam dua kategori, yaitu Kondisi *Good Condition* (Baik) dan *Reject* (Tolak). Proses klasifikasi ditunjukkan pada Gambar 1, di mana data input diambil dari dataset yang terlihat pada Gambar 2, yang berisi gambar-gambar *bitter melon* dalam berbagai kondisi. Gambar-gambar tersebut kemudian dianalisis dengan metode deep learning menggunakan CNN dan transfer learning model ResNet50 untuk menghasilkan keluaran mengenai kondisi buah.

Pemilihan CNN dan transfer learning model ResNet50 didasari oleh kemampuannya untuk mengekstrak fitur yang kompleks serta tingkat akurasi yang tinggi, meskipun memiliki lebih banyak parameter dibandingkan dengan model yang lebih sederhana.



Gambar 1. Arsitektur model CNN.



Gambar 2. Arsitektur transfer learning model ResNet50

Dalam penelitian ini, digunakan dua jenis arsitektur *deep learning*, yaitu CNN standar dan model *transfer learning* ResNet50, untuk melakukan klasifikasi terhadap kondisi buah pare (*bitter melon*). Gambar pertama menyajikan ilustrasi proses klasifikasi dengan CNN, di mana citra tanaman dianalisis melalui beberapa lapisan fully connected hingga menghasilkan keputusan klasifikasi ke dalam dua kategori: *Good Condition* dan *Reject*.

Gambar kedua memperlihatkan urutan tahapan pada model CNN secara umum, yang mencakup proses ekstraksi ciri menggunakan lapisan konvolusi dan pooling, kemudian dilanjutkan dengan proses klasifikasi pada bagian fully connected. Model ResNet50 memanfaatkan bobot pralatih dari dataset berskala besar seperti ImageNet, sehingga pelatihan dapat berlangsung lebih cepat dan akurat meskipun dataset penelitian relatif terbatas.

Kedua arsitektur ini menunjukkan kinerja yang efisien dalam mengenali kondisi tanaman berdasarkan visual citra, dan berpotensi untuk diterapkan dalam sistem pemantauan otomatis pada budidaya akuaponik.



Gambar 3. Contoh gambar kumpulan data *bitter melon*

Model pre-trained ResNet50 tersedia secara luas, sehingga dapat mempercepat pengembangan serta implementasi model klasifikasi kondisi tanaman *bitter melon* (pare). Kombinasi antara efisiensi komputasi, performa yang tinggi, dan ketersediaan model pre-trained menjadikan ResNet50 sebagai pilihan yang tepat untuk tugas klasifikasi ini.

ResNet50 merupakan bagian dari metode CNN dengan kerangka kerja *supervised learning*. Dalam penelitian ini, dataset yang digunakan adalah *Pare_Dataset*, yang terdiri dari citra tanaman *bitter melon* dengan dua kategori, yaitu *Good Condition* dan *Reject*. Ilustrasi dataset dapat dilihat pada Gambar 2. Sementara itu, Tabel 1 menunjukkan jumlah data yang digunakan untuk proses pelatihan dan pengujian model.

TABEL I. TRAINING DAN TESTING DATA SET

Class Name	Count	Training	Testing
Good Condition	50	45	5
Reject	50	45	5

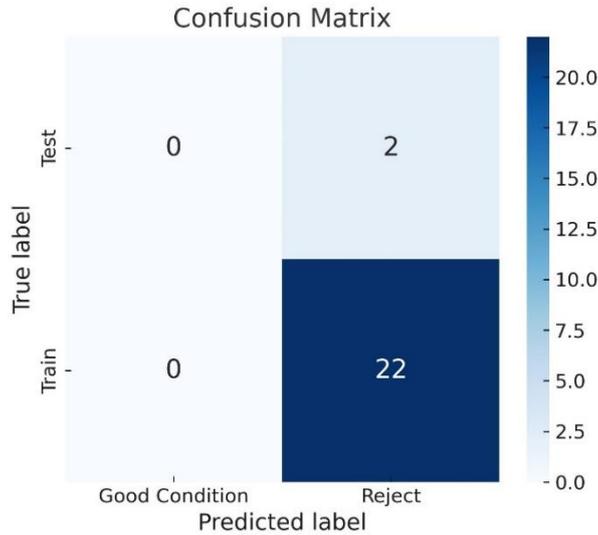
Gambar 1 dan 2 menampilkan arsitektur model ResNet50 dan arsitektur CNN yang diterapkan dalam penelitian ini. Model ini menerima input gambar dengan ukuran tetap 224×224 piksel dan menggunakan filter konvolusi berukuran 3×3 pada lapisan awal.

Untuk meningkatkan stabilitas dan mempercepat proses konvergensi selama pelatihan, diterapkan *batch normalization* sebanyak 2560. Teknik ini berfungsi untuk menormalkan output dari setiap lapisan sebelum aktivasi ReLU atau Softmax, sehingga dapat mencegah terjadinya masalah *gradient exploding* dan *gradient vanishing* selama proses training.

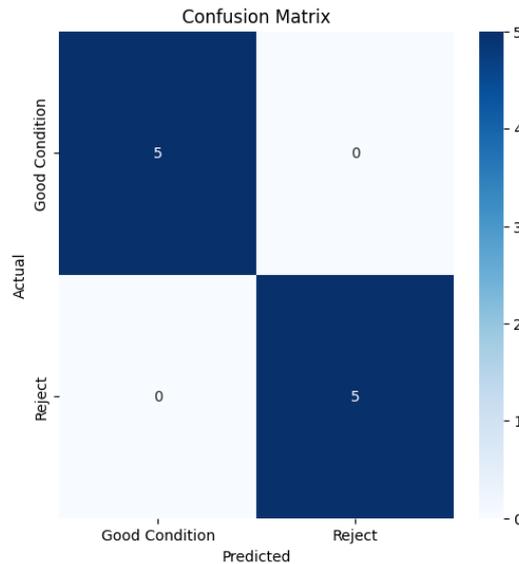
Selain itu, model ini menggunakan lapisan *fully connected* dengan 256 neuron untuk melakukan transformasi linear terhadap fitur-fitur yang telah diekstraksi oleh lapisan sebelumnya. Dengan demikian, model dapat membentuk representasi data yang lebih abstrak dan berperan sebagai *classifier* yang mengklasifikasikan tanaman *bitter melon* (pare) ke dalam kategori *Good Condition* atau *Reject*.

IV. HASIL DAN PEMBAHASAN

Eksperimen dilaksanakan dengan memanfaatkan kumpulan data dari *bitter melon* di Google Colab sebagai platform komputasi. Model tersebut dilatih dengan dataset yang sudah diolah dan dibagi menjadi dua kategori, yaitu *Good Condition* dan *Reject*.



Gambar 4. Confusion matrix Transfer Learning model ResNet50.



Gambar 5. Confusion matrix CNN.

Untuk mengevaluasi performa model pada data pelatihan dan pengujian, digunakan confusion matrix. Matriks ini menunjukkan distribusi prediksi model terhadap label asli dari dataset.

Beberapa metrik evaluasi yang digunakan dalam penelitian ini adalah:

1. Akurasi persentase prediksi yang benar terhadap seluruh data uji.

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+FN+TN}$$

2. Presisi keandalan model dalam mengidentifikasi kategori positif.

$$\text{Presisi} = \frac{TP}{TP+FP}$$

3. Recall kemampuan model dalam mendeteksi semua sampel yang termasuk kategori positif.

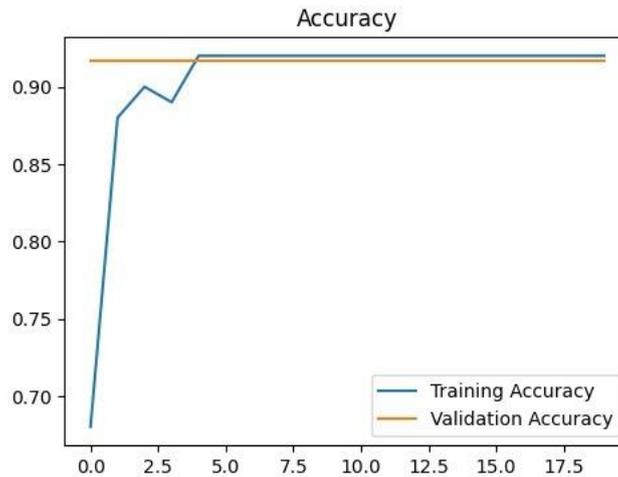
$$\text{Recall} = \frac{TP}{TP+FN}$$

4. F1-Score rata-rata harmonis antara presisi dan recall, berguna untuk mengevaluasi model pada dataset yang tidak seimbang.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$



Gambar 6. Grafik Accuracy CNN.



Gambar 7. Grafik Accuracy Transfer Learning model ResNet50.

Dua grafik di atas menampilkan kinerja model CNN dan ResNet50 berdasarkan akurasi selama proses pelatihan dan validasi. Pada grafik pertama, terlihat bahwa model CNN mengalami fluktuasi cukup signifikan pada akurasi validasi meskipun akurasi pelatihan meningkat secara konsisten hingga melampaui 95%. Variasi yang tajam ini mengindikasikan bahwa model kurang stabil dalam mengenali pola pada data validasi, kemungkinan disebabkan oleh keterbatasan jumlah data atau kerentanan terhadap variasi gambar.

Sebaliknya, grafik kedua yang menggambarkan performa model transfer learning ResNet50 menunjukkan peningkatan akurasi pelatihan yang cepat hingga mencapai lebih dari 90% hanya dalam beberapa epoch. Akurasi validasinya juga tampak stabil di angka sekitar 93%, menunjukkan bahwa model ini memiliki konsistensi yang lebih baik dalam proses pelatihan. Namun demikian, perbedaan kecil antara akurasi pelatihan dan validasi masih menunjukkan indikasi overfitting.

Evaluasi lebih lanjut pada data pengujian memperlihatkan bahwa model CNN berhasil mengklasifikasikan data uji dengan sangat baik, sedangkan ResNet50 mengalami kesulitan dalam mengenali data uji secara akurat. Hal ini memperkuat dugaan bahwa model mengalami overfitting terhadap data pelatihan. Untuk mengatasi permasalahan ini, diperlukan pendekatan seperti augmentasi citra, regulasi parameter, serta perluasan data uji guna meningkatkan kemampuan model dalam menghadapi berbagai kondisi nyata.

	precision	recall	f1-score	support
Test	0.00	0.00	0.00	2
Train	0.92	1.00	0.96	22
accuracy			0.92	24
macro avg	0.46	0.50	0.48	24
weighted avg	0.84	0.92	0.88	24

Gambar 8. Data Hasil Prediksi Transfer Learning model ResNet50.

	precision	recall	f1-score	support
Good Condition	1.00	1.00	1.00	5
Reject	1.00	1.00	1.00	5
accuracy			1.00	10
macro avg	1.00	1.00	1.00	10
weighted avg	1.00	1.00	1.00	10

Gambar 9. Data Hasil Prediksi CNN.

Pada Gambar 8 menunjukkan laporan klasifikasi yang membandingkan performa model pada data pelatihan (Train) dan data pengujian (Test). Model menunjukkan kinerja yang sangat baik pada data pelatihan, dengan precision sebesar 0.92, recall 1.00, dan f1-score 0.96, serta akurasi keseluruhan mencapai 92%. Namun, hasil yang sangat berbeda terlihat pada data pengujian, di mana precision, recall, dan f1-score semuanya bernilai 0.00, bahwa data tersebut mengindikasikan adanya kemungkinan overfitting, di mana model terlalu menyesuaikan pola dari data pelatihan tetapi gagal menggeneralisasi dengan baik ketika diberikan data baru. Hal ini menunjukkan bahwa meskipun model dapat mengenali pola dengan sangat baik dalam data latih, performanya tidak dapat diandalkan untuk melakukan klasifikasi pada data yang belum pernah dilihat sebelumnya. Untuk mengatasi masalah ini, diperlukan strategi seperti augmentasi data, regularisasi, atau peningkatan jumlah data pengujian agar model dapat lebih seimbang dalam mengenali pola di berbagai kondisi.

Pada gambar 9 klasifikasi ini memberikan analisis perbandingan kinerja model pada data pelatihan dan data pengujian. Model menunjukkan hasil yang sangat memuaskan pada data pengujian, dengan nilai presisi mencapai 1.00, recall 1.00, dan f1-score 1.00 untuk kedua kategori, serta akurasi total mencapai 100%. Temuan ini menunjukkan bahwa model berhasil mengklasifikasikan semua data uji secara akurat tanpa kesalahan. Namun, hasil ini harus dianalisis lebih lanjut, mengingat jumlah data pengujian yang dipakai terbilang sedikit, dengan hanya 5 sampel untuk setiap kategori. Oleh karena itu, diperlukan pengujian tambahan menggunakan dataset yang lebih besar agar dapat memastikan kemampuan generalisasi model.

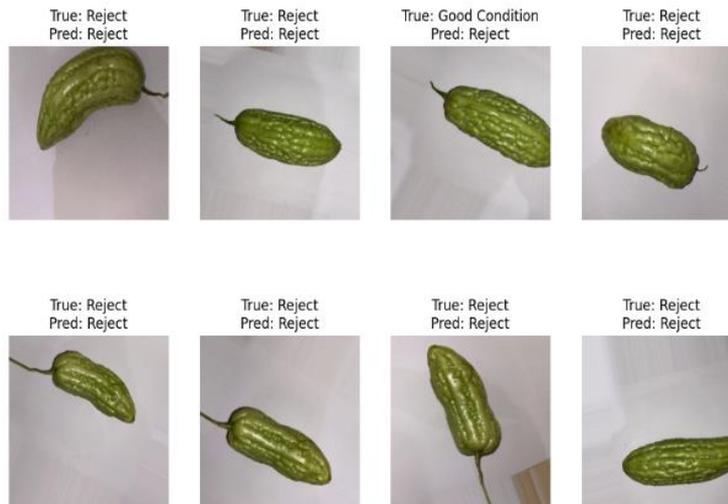
Dalam penelitian ini, model CNN yang saya terapkan mampu memberikan hasil klasifikasi yang sangat baik dengan F1-score, precision, dan recall yang semuanya bernilai 1.00 pada data uji. Sementara itu, model ResNet50 hanya menunjukkan performa tinggi pada data latih dengan F1-score sebesar 0.96, tetapi tidak mampu mengklasifikasikan data uji dengan baik (F1-score 0.00), yang mengindikasikan adanya gejala overfitting.

Ketika dibandingkan dengan hasil penelitian sebelumnya, temuan ini cukup relevan. Misalnya, Nugroho dan Supatman [8] melaporkan tingkat akurasi mencapai 93,5% dalam mendeteksi buah salak menggunakan CNN, sedangkan Yuliany et al. [9] memperoleh F1-score sekitar 0.91 dalam sistem klasifikasi hama tanaman padi. Keduanya menunjukkan bahwa CNN mampu memberikan hasil yang andal jika didukung oleh data yang mencukupi dan bervariasi.

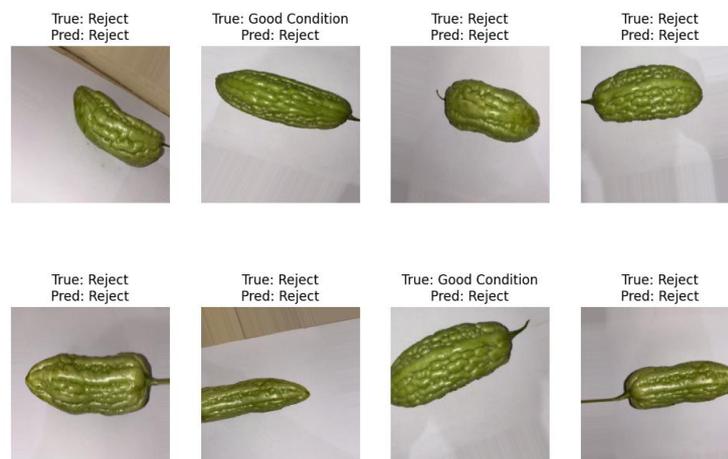
Studi oleh Nashrullah et al. [10] juga menyoroti tantangan serupa dalam penggunaan ResNet50, yaitu sensitivitas terhadap parameter pelatihan seperti jumlah epoch, yang dapat memicu overfitting jika tidak dikontrol secara tepat. Hasil tersebut sejalan dengan apa yang saya alami dalam model ResNet50, di mana kinerja saat pelatihan sangat baik namun tidak konsisten pada data uji.

Adapun penelitian oleh Oktafanda [11] yang menggunakan CNN dalam klasifikasi bibit kelapa sawit mencatat akurasi sekitar 96%, meskipun tidak secara rinci melaporkan metrik lain seperti F1-score. Jika dilihat dari sisi akurasi saja, hasil model CNN dalam penelitian saya menunjukkan keunggulan pada data uji, namun perlu dicatat bahwa ukuran dataset yang terbatas dapat memengaruhi validitas temuan tersebut.

Berdasarkan perbandingan ini, saya menyimpulkan bahwa CNN konvensional menunjukkan kinerja yang lebih stabil dalam konteks dataset yang kecil dan spesifik seperti pada penelitian ini. Sementara itu, penggunaan transfer learning seperti ResNet50 perlu disertai pengaturan parameter yang cermat dan jumlah data yang lebih besar agar dapat menghasilkan model yang lebih generalis dan adaptif.



Gambar 10. Hasil klasifikasi buah *bitter melon* dengan pendekatan metode transfer learning model ResNet50.



Gambar 11. Hasil klasifikasi buah *bitter melon* dengan pendekatan metode CNN.

Pada Gambar 10 dan 11 menampilkan hasil klasifikasi tanaman *bitter melon* (pare) menggunakan pendekatan deep learning. Setiap gambar disertai dengan label asli (True) dan prediksi model (Pred) yang terdiri dari dua kategori: *Good Condition* (Baik) dan *Reject* (Tolak). Model yang digunakan menunjukkan performa yang baik dalam mengidentifikasi kategori *Reject*, seperti terlihat dari kesesuaian antara label asli dan hasil prediksi.

Pendekatan deep learning dengan Convolutional Neural Networks (CNN) memungkinkan ekstraksi fitur visual secara otomatis, yang terbukti efektif dalam proses klasifikasi pare. Selain itu, penggunaan transfer learning dengan model pralatih seperti ResNet50 dapat meningkatkan akurasi, terutama saat bekerja dengan dataset berukuran lebih kecil, sebagaimana didukung oleh penelitian sebelumnya. Untuk meningkatkan generalisasi model, teknik augmentasi data seperti rotasi, flipping, dan zoom diterapkan agar model lebih mampu mengenali variasi dalam dataset.

V. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa metode klasifikasi tanaman *bitter melon* menggunakan CNN dapat secara efektif mengekstraksi fitur visual secara otomatis, sehingga meningkatkan akurasi klasifikasi. Penggunaan transfer learning dengan model pralatih ResNet50 memberikan keunggulan dalam menangani dataset terbatas. Untuk meningkatkan kemampuan generalisasi model, teknik augmentasi seperti rotasi, flipping, dan zoom diterapkan fungsinya memperkaya variasi dalam dataset.

Penerapan model ini dapat menjadi langkah awal dalam pengembangan sistem pemantauan tanaman berbasis kecerdasan buatan di lingkungan akuaponik. Namun, untuk meningkatkan kinerja model lebih lanjut, optimasi terhadap hyperparameter serta pengujian dengan dataset yang lebih beragam perlu dilakukan guna memastikan model dapat beradaptasi dengan berbagai kondisi nyata di lapangan.

DAFTAR PUSTAKA

- [1] S. Dwianto, F. N. Mubarak, D. Satriatama, T. Agustin, and S. Indonesia, "PENERAPAN CONVOLUTIONAL NEURAL NETWORK (CNN) DALAM," no. November, pp. 270–280, 2024.
- [2] P. Purwanto and S. Sumardi, "Perancangan Klasifikasi Tanaman Herbal Menggunakan Transfer Learning Pada Algoritma Convolutional Neural Network (CNN)," *J. Ilm. Infokam*, vol. 18, no. 2, pp. 105–118, 2022, doi: 10.53845/infokam.v18i2.328.
- [3] L. Handayani and 2018, "Pemanfaatan Lahan Sempit Dengan Sistem Budidaya Aquaponik," *Pros. Semin. Nas. Has. Pengabd. 2018*, pp. 118–126, 2018.
- [4] A. J. Bastari and A. Cherid, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Convolutional Neural Network dan Implementasi Model H5 Pada Aplikasi Desktop," *Simkom*, vol. 8, no. 2, pp. 199–207, 2023, doi: 10.51717/simkom.v8i2.194.
- [5] J. Alberto and D. Hermanto, "Klasifikasi Jenis Burung Menggunakan Metode CNN ResNet-50 [1]," *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 3, pp. 34–36, 2023.
- [6] I. P. Putra, R. Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritm.*, vol. 2, no. 2, pp. 102–112, 2022, doi: 10.35957/algoritme.v2i2.2360.
- [7] S. N. Nugraha, R. Pebrianto, and E. Fitri, "Penerapan Deep Learning Pada Klasifikasi Tanaman Paprika Berdasarkan Citra Daun Menggunakan Metode CNN," *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 8, no. 2, p. 15, 2023, doi: 10.51211/isbi.v8i2.2671.
- [8] J. Nugroho and Supatman, "Mendeteksi Salak BerLarva dan Tidak BerLarva Menggunakan Metode Convolutional Neural Network," *J. Inf. Syst. Artif. Intell.*, vol. 2, no. 1, pp. 56–60, 2021, doi: 10.26486/jisai.v2i1.64.
- [9] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [10] F. Nashrullah, S. A. Wibowo, and G. Budiman, "The Investigation of Epoch Parameters in ResNet-50 Architecture for Pornographic Classification: Investigasi Parameter Epoch Pada Arsitektur ResNet-50 Untuk Klasifikasi Pornografi," *Compleat. J. Comput. Electron. Telecommun.*, vol. 1, no. 1, 2020.
- [11] E. Oktafanda, "Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN)," *J. Inform. Ekon. Bisnis*, vol. 4, no. 3, pp. 72–77, 2022, doi: 10.37034/infeb.v4i3.143.
- [12] Dimas Mulya Saputra, Erwin Hermawan, and Sahid Agustian2, "Klasifikasi Kesehatan Pada Tanaman Padi Menggunakan Citra Unmanned Aerial Vehicle (Uav) Dengan Metode Convolutional Neural Networks (Cnn)," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. 3, pp. 308–318, 2023, doi: 10.33197/jitter.vol9.iss3.2023.1044.
- [13] A. Jinan, B. H. Hayadi, and U. P. Utama, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Convolutional Neural Network Melalui Citra Daun (Multilayer Perceptron)," *J. Comput. Eng. Sci.*, vol. 1, no. 2, pp. 37–44, 2022.
- [14] Muhammad Yusuf, Dewi Astria Faroek, Moh Saddam S Pattanang, Anggun M, and Ristanti Salam, "Sistem Pakar Diagnosa Penyakit Pada Tanaman Semangka Merah Menggunakan Metode CNN Berbasis Android," *J. Tek.*, vol. 13 No.1 Th, no. 1, pp. 99–109, 2024, [Online]. Available: <https://jurnal.umt.ac.id/index.php/jt/article/view/11830>
- [15] B. M. Sujatmiko, E. Yudaningsy, and P. Mudji Raharjo, "Convolution Neural Network Dengan Desain Jaringan Resnet Sebagai Metode Klasifikasi Tumor Kulit," *J. Simantec*, vol. 11, no. 1, pp. 53–64, 2022, doi: 10.21107/simantec.v11i1.14083.
- [16] A. Y. W. dan R. S. I Wayan Suartika E. P., "JURNAL TEKNIK ITS Vol. 5, No. 1, (2016) ISSN: 2337-3539 (2301-9271 Print)," *Klasifikasi Citra Menggunakan Convolutional Neural Netw. pada Caltech 101*, vol. Vol. 5, No, no. 1, pp. 1–2, 2016.
- [17] E. Lety Istikhomah Puspita Sari, "Revitalizing Strawberry Leaves: Developing a Tipburn and Leaf Spot Disease Detection System Through Convolution Analysis Using CNN Method," *JIMPS J. Ilm. Mhs. Pendidik. Sej.*, vol. 8, no. 3, pp. 1468–1474, 2023, [Online]. Available: <https://jim.usk.ac.id/sejarah>
- [18] R. H. Alfikri, M. S. Utomo, H. Februariyanti, and E. Nurwahyudi, "Pembangunan Aplikasi Penerjemah Bahasa Isyarat Dengan Metode Cnn Berbasis Android," *J. Teknoinfo*, vol. 16, no. 2, p. 183, 2022, doi: 10.33365/jti.v16i2.1752.
- [19] N. H. Harani, C. Prianto, and M. Hasanah, "Deteksi Objek Dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Python," *J. Tek. Inform.*, vol. 11, no. 3, pp. 47–53, 2019, [Online]. Available: <https://ejournal.ulbi.ac.id/index.php/informatika/article/view/658>
- [20] G. Y. Christiawan, R. A. Putra, A. Sulaiman, E. Poerbaningtyas, and S. W. Putri Listio, "Penerapan Metode Convolutional Neural Network (CNN) Dalam Mengklasifikasikan Penyakit Daun Tanaman Padi," *J-Intech*, vol. 11, no. 2, pp. 294–306, 2023, doi: 10.32664/j-intech.v11i2.1006.
- [21] D. Zahrah, N. Kurniati, and H. Darwis, "Digital Image Classification of Herbal Leaves Using Knn and Cnn With Glcm Features," *J. Tek. Inform.*, vol. 5, no. 1, pp. 61–67, 2024, [Online]. Available: <https://doi.org/10.52436/1.jutif.2024.5.1.1162>
- [22] R. Yohannes and M. E. Al Rivan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *J. Algoritm.*, vol. 2, no. 2, pp. 133–144, 2022, doi: 10.35957/algoritme.v2i2.2363.
- [23] N. Fadlia and R. Kosasih, "Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn)," *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 207–215, 2019, doi: 10.35760/tr.2019.v24i3.2397.
- [24] D. C. Agustin, M. A. Rosid, and N. Ariyanti, "Implementasi Convolutional Neural Network Untuk Deteksi Kesegaran Pada Apel," *J. Fasilkom*, vol. 13, no. 02, pp. 145–150, 2023, doi: 10.37859/jf.v13i02.5175.
- [25] H. Hidayat, F. Riana, and G. F. Laxmi, "Identifikasi Kualitas Benih Jahe Menggunakan Convolutional Neural Network (Cnn)," *INFOTECH J.*, vol. 9, no. 1, pp. 287–298, 2023, doi: 10.31949/infotech.v9i1.5458.