

Klasifikasi Jenis Buah Menggunakan Metode CNN

Ines Heidiani Ikasari^{1*}, Perani Rosyani², Resti Amalia³

^{1,2,3}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

Email : *dosen01374@unpam.ac.id

Abstrak

Klasifikasi jenis buah merupakan aplikasi penting dalam pengolahan citra, terutama di sektor pertanian, perdagangan, dan teknologi pangan. Proses identifikasi buah secara manual cenderung lambat dan rentan kesalahan, terutama karena variasi bentuk, warna, dan ukuran buah. Indonesia memiliki lebih dari 27 jenis buah yang diproduksi secara masif, namun pengenalan jenis buah masih banyak dilakukan secara manual. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis menggunakan metode Deep Learning, khususnya Convolutional Neural Network (CNN). CNN dipilih karena kemampuannya dalam mengenali pola visual dari citra digital melalui ekstraksi fitur menggunakan lapisan konvolusi dan pooling. Dataset citra buah diperoleh dari Kaggle dan terdiri dari 8 jenis buah yang diproses melalui tahap preprocessing seperti resizing, normalisasi, dan augmentasi data. Model CNN diuji pada dua skenario pembagian data: 80:20 dan 70:30. Pada skenario 80:20, model mencapai akurasi rata-rata 91% dan akurasi validasi 97%, sedangkan pada skenario 70:30 mencapai akurasi rata-rata 91% dan validasi 98%. Hasil ini menunjukkan bahwa CNN efektif untuk klasifikasi citra buah dengan akurasi tinggi.

Kata kunci: Klasifikasi Buah, Buah-Buahan, Deep Learning, Convolutional Neural Network, Pengolahan Citra.

1. Latar Belakang

Pemanfaatan teknologi digital dalam sektor pertanian terus berkembang, salah satunya melalui klasifikasi otomatis jenis buah menggunakan pengenalan citra digital. Di Indonesia, klasifikasi buah secara manual masih banyak dilakukan, meskipun metode ini memiliki banyak keterbatasan. Proses manual cenderung lambat, tidak konsisten, dan rentan terhadap kesalahan akibat keterbatasan pengamatan visual manusia. Metode manual seperti inspeksi visual memiliki keterbatasan dalam menangani variasi visual yang kompleks, dan ketergantungan pada manusia sering kali menghasilkan hasil yang tidak konsisten. Sebagai contoh, klasifikasi manual oleh pekerja di lapangan bisa berbeda tergantung pada pengalaman dan keterampilan individu, yang rentan terhadap kesalahan [1]. Oleh karena itu, diperlukan solusi teknologi yang dapat mengotomatisasi proses klasifikasi ini dan menghasilkan akurasi yang lebih tinggi. Dengan tingginya volume produksi buah dan keragaman jenis buah lokal, otomatisasi proses klasifikasi menjadi kebutuhan penting untuk meningkatkan efisiensi dan menjaga mutu produk. Penelitian oleh [2] menunjukkan bahwa implementasi sistem ini di pabrik pengolahan buah dapat mengurangi biaya tenaga kerja dan meningkatkan throughput produksi.

Convolutional Neural Network (CNN) telah menjadi salah satu metode paling efektif dalam pengolahan citra digital karena kemampuannya dalam mengenali pola visual kompleks tanpa memerlukan ekstraksi fitur manual. Berbagai studi sebelumnya telah membuktikan efektivitas CNN dalam klasifikasi objek visual, termasuk buah. Penelitian oleh [3] menunjukkan bahwa CNN mampu mengklasifikasikan hingga 15 jenis buah dan sayuran secara konsisten meskipun dalam kondisi pencahayaan dan latar belakang yang beragam. Penelitian oleh [4] mengaplikasikan CNN untuk klasifikasi buah dan berhasil mencapai hasil yang akurat dengan menggunakan dataset citra buah yang bervariasi. [5] menggunakan CNN untuk mengembangkan model klasifikasi buah dari citra dengan tingkat akurasi yang sangat tinggi. Penelitian [6] mengembangkan pendekatan *transfer learning* untuk mengadaptasi model yang sudah dilatih pada dataset besar seperti ImageNet, dan menunjukkan hasil klasifikasi buah yang sangat baik. Selain itu, [7] menekankan pentingnya ketersediaan dataset yang beragam dan representatif, serta penggunaan teknik augmentasi citra seperti rotasi, flipping, dan scaling untuk meningkatkan generalisasi model CNN.

Meskipun CNN telah terbukti andal, penerapannya dalam klasifikasi buah masih menghadapi sejumlah tantangan. Di sektor agrikultur, [8] melakukan survei mengenai penerapan deep learning, khususnya CNN, dalam berbagai aplikasi pertanian. Variasi yang besar dalam bentuk, warna, dan tekstur buah membuat model sukar untuk

mencapai akurasi yang konsisten. Selain itu, pencahayaan yang tidak seragam serta latar belakang yang kompleks saat pengambilan gambar menjadi faktor yang memengaruhi performa model. CNN telah terbukti efektif dalam berbagai tugas klasifikasi citra karena kemampuannya dalam mengekstraksi dan mengenali pola visual yang kompleks, seperti tekstur dan warna, tanpa memerlukan fitur yang diidentifikasi secara manual [9]. Tantangan lainnya adalah keterbatasan data lokal berkualitas tinggi yang dapat digunakan untuk pelatihan model, serta perlunya strategi augmentasi data yang sesuai agar hasil pelatihan tetap relevan dengan kondisi nyata.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk mengembangkan model CNN yang dapat digunakan untuk mengklasifikasikan jenis buah secara otomatis dan akurat. Model dikembangkan dengan memanfaatkan dataset terbuka dari berbagai jenis buah, yang kemudian diproses melalui tahapan seperti *resizing*, normalisasi, dan augmentasi untuk meningkatkan kualitas dan variasi data. Arsitektur CNN yang digunakan dirancang untuk mengekstraksi fitur visual penting dari citra buah dan mengklasifikasikannya secara otomatis.

Kebaruan dari penelitian ini terletak pada pengembangan model CNN berbasis data buah tropis Indonesia, serta penerapan strategi *preprocessing* dan augmentasi data secara sistematis untuk menghadapi tantangan variasi visual pada buah. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi buah otomatis yang efisien dan aplikatif, khususnya di sektor pertanian dan distribusi buah lokal.

2. Metode Penelitian

Tujuan dari penelitian ini adalah merancang model *Convolutional Neural Network* (CNN) yang mampu melakukan klasifikasi jenis buah berdasarkan citra digital. Penjabaran detail mengenai tiap tahap dalam proses penelitian, mulai dari tahap pengumpulan data hingga penyusunan laporan hasil, disampaikan dalam bagian berikut:



Gambar 1 Alur Penelitian

2.1. Pengumpulan Data

Proses pengumpulan data menjadi tahap awal yang sangat penting dalam penelitian ini. Data yang dihimpun berupa citra buah yang akan digunakan untuk proses pelatihan dan pengujian model CNN. Sumber utama data berasal dari repositori terbuka seperti Kaggle, yang menyediakan *dataset* berbagai jenis buah. Dalam studi ini, digunakan *dataset* Fruits-360 yang memuat 90.380 gambar dari 131 kategori buah. Namun, penelitian ini hanya memfokuskan pada delapan jenis buah, yaitu alpukat, jambu, jeruk, lemon, nanas, pisang, salak, dan semangka. Setiap gambar memiliki keragaman karakteristik seperti warna, ukuran, dan bentuk yang berbeda-beda.

Ketersediaan *dataset* yang cukup besar dan bervariasi sangat penting untuk memastikan model mampu mengenali buah dalam berbagai kondisi visual. Selain itu, proses pengumpulan data juga mencakup seleksi gambar dengan kualitas tinggi guna mengurangi potensi kesalahan klasifikasi akibat citra yang kabur atau tidak jelas. Pemberian label yang akurat pada setiap citra juga menjadi aspek penting agar data sesuai dengan kategori buah masing-masing, yang berperan krusial dalam proses pelatihan model secara efektif.

2.2. Preprocessing Data

Setelah proses pengumpulan data selesai dilakukan, tahap selanjutnya adalah *preprocessing* atau pengolahan awal data citra. Pada tahap ini, semua gambar diubah ukurannya agar memiliki dimensi yang seragam dan sesuai dengan kebutuhan *input* dari arsitektur *Convolutional Neural Network* (CNN) yang akan digunakan. Selain itu, dilakukan juga augmentasi data untuk meningkatkan keragaman citra tanpa mengubah label aslinya. Teknik augmentasi yang digunakan meliputi rotasi, pembalikan, dan perubahan skala. Teknik augmentasi data seperti rotasi, *flipping*, dan *scaling* akan digunakan untuk meningkatkan variasi visual dalam *dataset* dan meningkatkan generalisasi model [10]. Dalam penelitian [11] menunjukkan bahwa penggunaan augmentasi data bersama dengan *dropout* secara signifikan meningkatkan kinerja CNN dalam klasifikasi citra buah. Tujuan dari augmentasi ini adalah untuk menjadikan model lebih tangguh dalam mengenali buah dengan berbagai sudut pandang serta kondisi pencahayaan yang berbeda. Proses ini juga membantu mengurangi risiko *overfitting*, yaitu kondisi ketika model terlalu menyesuaikan diri dengan data pelatihan sehingga performanya menurun saat diuji pada data baru yang belum pernah dilihat sebelumnya.

2.3. Pengembangan Model

Pada tahap pengembangan model, dilakukan perancangan arsitektur CNN sekaligus proses pelatihan. Perancangan ini mencakup pemilihan lapisan-lapisan jaringan serta pengaturan parameter penting seperti jumlah *filter* pada lapisan konvolusi, ukuran kernel, dan jenis fungsi aktivasi yang digunakan. Struktur CNN umumnya terdiri dari sejumlah lapisan konvolusi yang diikuti oleh lapisan *pooling*, kemudian diakhiri dengan satu atau lebih lapisan *fully connected* yang berfungsi melakukan klasifikasi akhir.

Setelah arsitektur ditentukan, model dilatih menggunakan data citra yang telah melalui tahap *preprocessing*. Proses pelatihan ini memanfaatkan algoritma *backpropagation* serta metode optimisasi seperti Adam atau *Stochastic Gradient Descent* (SGD) untuk menyesuaikan bobot dalam jaringan berdasarkan nilai kesalahan yang dihasilkan. Selama proses pelatihan berlangsung, penting untuk terus memantau nilai *loss* dan akurasi pada data pelatihan maupun data validasi guna mengevaluasi performa model serta melakukan penyesuaian parameter apabila diperlukan.

2.4. Evaluasi Model

Setelah proses pelatihan selesai, tahap selanjutnya adalah evaluasi model. Evaluasi dilakukan dengan menggunakan data uji yang sebelumnya tidak pernah digunakan selama pelatihan, guna mengukur sejauh mana model mampu mengenali pola secara umum di luar data yang telah dipelajarinya. Untuk menilai kinerjanya, digunakan beberapa metrik evaluasi seperti akurasi, presisi, dan *recall*. Akurasi menunjukkan seberapa besar persentase citra yang berhasil diklasifikasikan dengan benar oleh model. Sementara itu, presisi digunakan untuk mengetahui seberapa tepat prediksi positif yang dihasilkan, dan *recall* mengukur seberapa banyak dari seluruh data positif yang berhasil dikenali secara benar. Apabila model menunjukkan performa yang baik pada data uji, hal ini menandakan bahwa model mampu melakukan generalisasi dengan baik dan berpotensi digunakan untuk tugas klasifikasi buah dalam kondisi nyata.

2.5. Pelaporan

Tahapan terakhir dalam proses penelitian ini adalah penyusunan laporan. Semua hasil yang diperoleh dirangkum ke dalam dokumen ilmiah yang mencakup penjelasan tentang metode yang digunakan, temuan utama, serta pembahasan mengenai makna dan dampak dari hasil tersebut. Dalam laporan tersebut juga dapat disertakan saran untuk penelitian lanjutan maupun pengembangan model secara lebih lanjut.

Penyusunan laporan ini memiliki peran penting, tidak hanya sebagai bentuk dokumentasi akademik, tetapi juga sebagai sarana untuk menyebarkan pengetahuan kepada komunitas ilmiah dan pelaku industri yang berpotensi memanfaatkan teknologi serupa. Keseluruhan proses penelitian ini menggabungkan pendekatan komputasi modern dan analisis data untuk menjawab tantangan dalam klasifikasi buah, menawarkan solusi yang lebih efisien dan otomatis dibandingkan pendekatan manual yang masih banyak digunakan namun cenderung lebih lambat dan kurang akurat.

3. Hasil dan Diskusi

Hasil dan diskusi pada bagian ini dimulai dari hasil pengumpulan data, hasil *preprocessing data*, hasil perancangan model CNN, hasil pelatihan dan pengujian model, hasil evaluasi model, rata-rata hasil pengujian, dan *output* hasil prediksi.

3.1. Hasil Pengumpulan Data

Dalam penelitian ini, pengumpulan dataset dilakukan dengan memanfaatkan situs penyedia data terbuka, yaitu kaggle.com. Dataset yang digunakan adalah Fruit-360, yang diunduh secara gratis melalui platform tersebut. Dataset ini mencakup total 90.380 gambar yang terbagi ke dalam 131 kategori buah yang berbeda. Seluruh gambar disimpan dalam format JPG dengan resolusi 100x100 piksel. Dari keseluruhan jenis buah yang tersedia, peneliti memilih delapan jenis buah untuk digunakan dalam penelitian, yaitu alpukat, jambu, jeruk, lemon, nanas, pisang, salak, dan semangka, dengan total 4.320 gambar dengan total gambar pada folder training sebanyak 3.200, sedangkan folder test 1.120 gambar. Untuk setiap jenis buah, data latih terdiri dari 400 gambar, sedangkan data uji mencakup 140 gambar.

Dataset Fruits-360 digunakan dalam penelitian ini karena memiliki kualitas yang baik, cakupan data yang lengkap, dan dapat diakses secara gratis untuk keperluan akademik. Seluruh citra dalam dataset diambil dalam kondisi terkontrol, sehingga perbedaan pencahayaan maupun sudut pengambilan gambar dapat diminimalkan. Hal ini berkontribusi terhadap peningkatan akurasi model dalam melakukan klasifikasi.

3.2. Hasil *Preprocessing Data*

Setelah proses pengumpulan *dataset* berupa gambar dari delapan jenis buah selesai dilakukan, tahap selanjutnya adalah *preprocessing data*. Tahapan awal dalam *preprocessing* ini adalah membagi dataset. Berdasarkan visualisasi pembagian data pada masing-masing kelas, terdapat 400 gambar untuk setiap jenis buah, sehingga total data latih (*training data*) berjumlah 3.200 gambar dan data uji (*test data*) berjumlah 1.120 gambar. Selanjutnya, data latih ini akan dibagi kembali untuk keperluan validasi menggunakan fungsi *train_test_split* dari pustaka Scikit-learn. Penelitian ini menerapkan dua skenario perbandingan data, yaitu pembagian rasio antara data latih, validasi, dan uji, sebagaimana dirinci dalam Tabel 1. Komposisi pembagian ini sangat menentukan jumlah data yang digunakan untuk masing-masing keperluan dan secara langsung memengaruhi akurasi akhir dari model yang dibangun.

Tabel 1. Pembagian Dataset

Data	Split Dataset 1	Split Dataset 2
Training : Validasi	80 : 20	70 : 30
Total Data	2560 : 640	2240 : 960

Setelah pembagian *dataset* dilakukan, proses berikutnya adalah augmentasi data. Tahapan ini bertujuan untuk meningkatkan jumlah dan variasi citra dalam *dataset* dengan menghasilkan gambar baru yang merupakan modifikasi dari data latih yang sudah ada. Teknik augmentasi dilakukan menggunakan fungsi *ImageDataGenerator* dari *TensorFlow library*. Dalam penelitian ini, digunakan tujuh parameter augmentasi.

Tabel 2. Parameter Augmentasi Data

Parameter	Nilai
<i>rescale</i>	1/255
<i>zoom_range</i>	0.2
<i>shear_range</i>	0.2
<i>rotation_range</i>	20
<i>horizontal_flip</i>	True
<i>width_shift_range</i>	0.2
<i>height_shift_range</i>	0.2

3.3. Hasil Perancangan Model CNN

Pada penelitian ini, model *Convolutional Neural Network* (CNN) dirancang menggunakan arsitektur *Sequential* dengan beberapa lapisan konvolusi, *pooling*, dan *fully connected*. Model ini dibangun dengan menggunakan *library* TensorFlow dan Keras. Arsitektur model ini terdiri dari beberapa lapisan utama sebagai berikut.

a. *Convolutional Layer* dan *Pooling Layer*

- 1) Lapisan pertama adalah Conv2D dengan 32 filter, ukuran kernel 3x3, dan fungsi aktivasi ReLU. Lapisan ini diikuti oleh MaxPooling2D dengan ukuran *pool* 2x2.
- 2) Lapisan kedua adalah Conv2D dengan 64 filter, ukuran kernel 3x3, dan fungsi aktivasi ReLU, diikuti oleh MaxPooling2D dengan ukuran *pool* 2x2.
- 3) Lapisan ketiga adalah Conv2D dengan 128 filter, ukuran kernel 3x3, dan fungsi aktivasi ReLU, diikuti oleh MaxPooling2D dengan ukuran *pool* 2x2.

b. *Flatten* dan *Fully-Connected Layer*

- 1) Lapisan *Flatten* digunakan untuk mengubah data dari bentuk dua dimensi menjadi satu dimensi.
- 2) Lapisan *Dense* dengan 512 unit neuron dan fungsi aktivasi ReLU.
- 3) *Dropout* dengan tingkat 0.5 untuk mengurangi *overfitting*.
- 4) Lapisan *output Dense* dengan 8 unit neuron dan fungsi aktivasi *softmax* untuk klasifikasi ke dalam 8 kategori buah.

3.4. Hasil Pelatihan dan Pengujian Model

Hasil pelatihan model untuk TFC-1 bisa dilihat pada gambar di berikut ini.

Tabel 3. Hasil Pelatihan Model TFC-1

Epoch	Accuracy	Loss	Val Accuracy	Val Loss
1/5	0.2217	2.1164	0.2048	1.8522
2/5	0.4107	1.6325	0.6000	0.9213
3/5	0.6834	0.8275	0.8000	0.4238
4/5	0.8409	0.4139	0.9000	0.3704
5/5	0.9174	0.2227	0.9778	0.0920

Berdasarkan hasil pelatihan, akurasi pada data latih mengalami peningkatan bertahap dari 22,17% pada *epoch* pertama hingga mencapai 91,74% pada *epoch* kelima. Begitu pula dengan akurasi validasi yang meningkat secara konsisten dari 20,48% menjadi 97,78%. Perkembangan ini menunjukkan bahwa model mampu belajar secara efektif tanpa memperlihatkan gejala *overfitting*. Selain itu, nilai *loss* pada data latih menurun dari 2,1164 menjadi 0,2227, sedangkan *loss* pada data validasi juga menunjukkan penurunan stabil dari 1,8522 menjadi 0,0920. Tren penurunan ini mengindikasikan bahwa model tidak hanya belajar dengan baik, tetapi juga mempertahankan kemampuan generalisasi terhadap data baru.

Lalu, hasil pelatihan model untuk TFC-2 bisa dilihat pada gambar berikut.


Tabel 4. Hasil Pelatihan Model TFC-2

Epoch	Accuracy	Loss	Val Accuracy	Val Loss
1/5	0.2263	2.0078	0.5600	1.1534
2/5	0.5718	1.2082	0.7000	0.6661
3/5	0.7553	0.6922	0.9211	0.3461
4/5	0.7918	0.5367	0.9000	0.2461
5/5	0.9151	0.2672	0.9800	0.0673

Berdasarkan hasil pelatihan, akurasi pada data latih meningkat secara bertahap dari 22,63% pada *epoch* pertama hingga mencapai 91,51% pada *epoch* kelima. Akurasi pada data validasi juga menunjukkan peningkatan yang konsisten, dari 56,00% menjadi 98,00%. Hal ini mengindikasikan bahwa model mampu mempelajari pola dengan baik tanpa memperlihatkan tanda-tanda *overfitting*. Selain itu, nilai *loss* pada data latih mengalami penurunan dari 2,0078 menjadi 0,2672, sedangkan pada data validasi, nilai *loss* menurun dari 1,1534 menjadi 0,0673. Penurunan yang stabil ini memperkuat bahwa model memiliki kemampuan generalisasi yang baik dan tidak terlalu menyesuaikan diri terhadap data pelatihan.

3.5. Hasil Evaluasi Model


Setelah seluruh tahapan pelatihan model diselesaikan, dilakukan proses evaluasi untuk menilai sejauh mana kinerja model dan menentukan apakah model telah mencapai performa yang optimal atau masih memerlukan pelatihan tambahan. Berikut ini merupakan hasil evaluasi model dalam penelitian ini.



Gambar 2 *Confusion Matrix* Model TFC -1

Tabel 5. Hasil Matriks TFC-1

Matriks	Kelas							
	Alpukat	Jambu	Jeruk	Lemon	Nanas	Pisang	Salak	Semangka
Accuracy	98.39%							
Precision	100%	97%	100%	100%	100%	100%	90%	100%
Recall	100%	100%	100%	100%	89%	97%	100%	100%
F1-score	100%	99%	100%	100%	94%	99%	95%	100%



Gambar 3 *Confusion Matrix* Model TFC -2

Tabel 6. Hasil Matriks TFC-2

Matriks	Kelas							
	Alpukat	Jambu	Jeruk	Lemon	Nanas	Pisang	Salak	Semangka
Accuracy	97.23%							
Precision	100%	98%	100%	100%	100%	100%	100%	100%
Recall	100%	100%	100%	85%	100%	93%	100%	100%
F1-score	100%	90%	100%	92%	100%	96%	100%	100%

3.6. Rata-Rata Hasil Pengujian

Pada skenario pembagian *dataset* dengan rasio 80:20, model menunjukkan kinerja yang sangat baik. Selama proses pelatihan selama lima *epoch*, rata-rata nilai *loss* tercatat sebesar 0,2227, yang menunjukkan kemampuan model dalam meminimalkan kesalahan prediksi. Akurasi rata-rata yang dicapai sebesar 91,74% tergolong tinggi, sementara akurasi validasi juga menunjukkan hasil yang sangat memuaskan sebesar 97,78%. Hasil ini diperkuat oleh rendahnya nilai rata-rata *loss* pada data validasi sebesar 0,0920, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang kuat terhadap data yang belum pernah dikenali sebelumnya.

Sementara itu, pada pembagian *dataset* dengan rasio 70:30, performa model tetap stabil dan menunjukkan hasil yang kompetitif. Meskipun rata-rata *loss* meningkat menjadi 0,2672, yang menunjukkan sedikit peningkatan kesalahan, akurasi rata-rata hanya mengalami penurunan kecil menjadi 91,51%. Menariknya, akurasi validasi justru meningkat menjadi 98,00%, dan nilai *Val_Loss* menurun menjadi 0,0673. Hal ini mengindikasikan bahwa model mampu mengenali pola dengan lebih baik pada data uji dan memiliki kemampuan generalisasi yang lebih tinggi pada skenario ini.


Secara keseluruhan, model menunjukkan performa yang konsisten dan unggul pada kedua skenario pembagian data. Pembagian 80:20 memberikan hasil yang seimbang antara akurasi dan *loss*, sedangkan pembagian 70:30 menghasilkan peningkatan pada akurasi validasi serta penurunan pada *Val_Loss*, meskipun terdapat sedikit peningkatan pada rata-rata *loss*. Temuan ini menunjukkan bahwa model memiliki ketahanan yang baik terhadap variasi dalam proporsi data uji dan tetap mampu mempertahankan performa optimal dalam berbagai kondisi pengujian.

Tabel 7. Rata-Rata Hasil Pengujian

Split Dataset	Epoch	Rata-Rata Accuracy	Rata-Rata Loss	Rata-Rata Val Accuracy	Rata-Rata Val Loss
80 : 20	5	0.9174	0.2227	0.9778	0.0920
70 : 30	5	0.9151	0.2672	0.9800	0.0673


3.7. Output Hasil Prediksi

Gambar 4 menunjukkan model berhasil memprediksi gambar-gambar yang diambil dari folder *test* dengan tepat dan dengan tingkat *confident* yang sangat besar di setiap kelasnya.



Gambar 4 Hasil Prediksi pada *Test Data*

Gambar 5 menunjukkan model berhasil memprediksi gambar-gambar yang diambil dari Google dengan tepat dan dengan tingkat *confident* yang sangat besar di setiap kelasnya. Tetapi perlu diketahui, tidak semua gambar yang diambil dari Google akan diprediksi dengan baik dan benar karena keterbatasan dari *dataset* yang digunakan pada penelitian ini.



Gambar 5 Hasil Prediksi Data Baru

4. Kesimpulan

Penelitian ini menunjukkan bahwa penerapan metode *Convolutional Neural Network* (CNN) secara signifikan mampu meningkatkan efisiensi dan akurasi dalam proses pengenalan serta klasifikasi buah. CNN dapat mengotomatiskan tahapan ekstraksi fitur dari citra buah, yang sebelumnya memerlukan proses manual. Melalui tahapan *preprocessing* seperti perubahan ukuran gambar, normalisasi, dan augmentasi data, model dapat dilatih dengan lebih efektif. Proses ini tidak hanya mempercepat klasifikasi, tetapi juga membantu mengurangi tingkat kesalahan yang terjadi selama identifikasi citra. Model CNN dilatih menggunakan *dataset* citra buah yang diperoleh dari sumber terbuka seperti Kaggle, dan telah melalui proses pra-pemrosesan. Model ini berhasil mengenali delapan jenis buah dengan performa yang baik. Hasil pelatihan menunjukkan bahwa model mampu mencapai akurasi rata-rata sebesar 91%, dengan akurasi validasi berkisar antara 97% - 98%, tergantung pada skenario pembagian data 70:30 dan 80:20. Temuan ini memperkuat bahwa CNN merupakan metode yang efektif dalam membangun sistem klasifikasi buah yang andal dan akurat. Sebagai saran untuk penelitian selanjutnya, dapat dipertimbangkan penerapan algoritma klasifikasi lain untuk dibandingkan dengan CNN, serta memperluas jumlah jenis buah yang diklasifikasikan. Selain itu, memperbanyak jumlah citra dalam dataset dan memastikan variasi yang lebih tinggi pada setiap kelas buah juga sangat penting. Hal ini bertujuan untuk meningkatkan kemampuan generalisasi model, serta mengurangi risiko terjadinya *overfitting* maupun *underfitting* pada data pelatihan.

Referensi

1. Koirala, A., Walsh, K. B., Wang, Z., & McCarthy, C. (2019). Deep learning–Method overview and review of use for fruit detection and yield estimation. *Computers and Electronics in Agriculture*, 162, 219-234. <https://doi.org/10.1016/j.compag.2019.04.017>
2. Chen, F., et al. (2019). Automated Fruit Sorting Machines Using Deep Learning. *Journal of Automation in Agriculture*.
3. Tm, A., Shilpa, A., & Avinash, K. (2020). Identification and classification of fruits using deep learning. *International Journal of Computer Applications*, 177(34), 1-6. <https://doi.org/10.5120/ijca2020919939>.
4. Hossain, M. S., Mou, R. J., Chakraborty, S., & Hossain, M. A. (2019). Fruit classification using convolutional neural network. *International Journal of Electrical and Computer Engineering*, 9(5), 4100-4107. <https://doi.org/10.11591/ijece.v9i5.pp4100-4107>
5. Mureşan, H., & Oltean, M. (2018). Fruit recognition from images using deep learning. *Acta Universitatis Sapientiae, Informatica*, 10(1), 26-42. <https://doi.org/10.2478/ausi-2018-0002>.
6. Zhang, Y., & Liu, X. (2021). Transfer Learning with Convolutional Neural Networks for Fruit Image Classification. *Journal of Food Engineering*.
7. Kim, D., & Park, J. (2022). Data Augmentation Techniques for Robust Fruit Classification Models. *Computational Intelligence and Neuroscience*.
8. Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
9. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
10. Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>.
11. Wang, Z., Walsh, K. B., Verma, B., & Whitty, M. (2018). Robustness of deep learning models in fruit classification under diverse conditions. *Journal of Imaging*, 4(4), 54. <https://doi.org/10.3390/jimaging4040054>.