

Classification of Fresh and Rotten Fruits and Vegetables Using a Customized Convolutional Neural Network

M. SYAFIQ UBAIDILLAH, REYHAN DANY INDRARTO, DWI ROLLIAWATI, AHMAD YUSUF

Universitas Islam Negeri Sunan Ampel Surabaya
Email: ubaidillahsyafiq349@gmail.com

Received 7 Desember 2024 | *Revised* 28 April 2025 | *Accepted* 16 Mei 2025

ABSTRAK

Penelitian ini mengembangkan model Convolutional Neural Network (CNN) berbasis ResNet-18 untuk mengklasifikasikan buah dan sayuran berdasarkan jenis dan tingkat kesegarannya secara simultan. Permasalahan yang diangkat adalah bagaimana model dapat melakukan klasifikasi ganda dalam satu arsitektur serta menganalisis pengaruh kesegaran terhadap akurasi klasifikasi jenis. Dataset Fresh and Rotten berisi 30.357 citra dari sembilan kategori digunakan. Model dimodifikasi dengan tiga blok tambahan yang memisahkan tugas klasifikasi. Pelatihan dilakukan dengan pendekatan multitugas menggunakan loss gabungan dan optimisasi berbeda. Hasil menunjukkan akurasi 99% untuk jenis dan 98% untuk kesegaran. Temuan ini menunjukkan efektivitas pendekatan multitugas CNN dalam mendukung inspeksi kualitas produk hortikultura secara otomatis.

Kata kunci: *Convolutional Neural Network, klasifikasi buah dan sayuran, ResNet-18, kesegaran, pengolahan citra*

ABSTRACT

This study proposes a customized Convolutional Neural Network (CNN) model based on ResNet-18 to simultaneously classify fruits and vegetables by type and freshness. The research addresses how a single architecture can handle dual classification tasks and explores the influence of freshness on type classification accuracy. The Fresh and Rotten dataset, consisting of 30,357 images across nine categories, was used. The model includes three additional blocks that separate the classification tasks. Training applied a multitask learning approach with a combined loss and distinct optimization. Results show 99% accuracy for type classification and 98% for freshness. The findings highlight the effectiveness of multitask CNN in supporting automated horticultural quality inspection.

Keywords: *Convolutional Neural Network, fruit and vegetable classification, ResNet-18, freshness, image processing*

1. PENDAHULUAN

Buah dan sayuran adalah sumber gizi utama yang penting untuk kesehatan tubuh. Kandungan seperti vitamin, mineral, antioksidan, dan serat membantu mencegah penyakit kronis seperti kanker, diabetes, dan hipertensi. Namun, buah dan sayuran mudah rusak, sehingga kehilangan nilai gizinya dan menjadi media pertumbuhan bakteri yang berbahaya jika dikonsumsi (**Hamidah, 2015**).

Dalam proses distribusi, pemisahan antara buah segar dan busuk sangat penting untuk menjaga kualitas produk. Metode manual yang mengandalkan inspeksi visual masih banyak digunakan, tetapi metode ini membutuhkan waktu lama, biaya tinggi, dan rawan kesalahan, terutama pada volume produk yang besar (**Munfaati & Witanti, 2024**).

Penelitian ini bertujuan untuk mengembangkan model kustom berbasis CNN yang mampu melakukan klasifikasi buah dan sayuran tidak hanya berdasarkan jenisnya tetapi juga tingkat kesegarannya secara simultan dalam satu arsitektur. Selain itu, penelitian ini juga bertujuan untuk menganalisis apakah tingkat kesegaran (*fresh* atau *rotten*) mempengaruhi akurasi model dalam mengidentifikasi jenis buah atau sayuran. Pemahaman ini penting untuk meningkatkan keandalan sistem klasifikasi otomatis, terutama pada kondisi visual yang tidak ideal.

Model ini memanfaatkan arsitektur ResNet-18 sebagai pondasi, yang kemudian dimodifikasi dengan menambahkan beberapa blok jaringan tambahan. Blok pertama dirancang untuk mengekstraksi fitur visual utama dari gambar, sementara dua blok lainnya bertugas untuk mengklasifikasikan jenis buah dan tingkat kesegarannya secara terpisah. Dengan strategi ini, model tidak hanya mampu memisahkan buah segar dan busuk dengan akurasi tinggi, tetapi juga mengidentifikasi sembilan jenis buah dan sayuran yang berbeda.

Berdasarkan permasalahan tersebut, penelitian ini merumuskan dua fokus utama. Pertama, bagaimana merancang dan mengoptimalkan arsitektur CNN *customize* berbasis ResNet-18 untuk klasifikasi jenis dan kesegaran buah dan sayuran secara simultan. Kedua, apakah terdapat hubungan antara tingkat kesegaran buah atau sayuran (*fresh* atau *rotten*) dengan akurasi klasifikasi jenisnya. Hal ini penting untuk dikaji mengingat kondisi visual buah yang sudah sangat rusak dapat mempersulit proses identifikasi jenisnya.

Pengklasifikasian citra dapat dilakukan dengan menggunakan algoritma CNN yang mana sangat baik jika dilakukan dengan menggunakan data citra yang jumlahnya banyak, akan tetapi memerlukan waktu yang lebih lama dengan algoritma pembelajaran mesin klasik (SVM) (**Prinzky & Lubis, 2022**). CNN digunakan dalam proses klasifikasi data yang menggunakan *Metode Supervised Learning*, yang mana didalam metode terdapat data latih dan target data dengan tujuan untuk mengelompokkan data ke dalam data yang ada (**Rahmadhani & Marpaung, 2023**). Selain itu Secara umum klasifikasi bisa diartikan sebagai suatu proses pengelompokan, dalam arti lain klasifikasi memisahkan suatu objek yang berbeda (**Cahya, dkk, 2021**). ResNet-18 adalah arsitektur *Convolutional Neural Network* (CNN) yang populer, dirancang untuk mengatasi masalah *vanishing gradients* pada jaringan neural yang sangat dalam dengan menggunakan *residual connections* atau *shortcut connections* (**Zhao, dkk, 2022**).


Pada penelitian ini menggunakan dataset *Fresh and Rotten Classification* dengan 9 jenis buah dan sayuran. Jenis itu antara lain *apples, banana, bittergroud, capsicum, cucumber, okra, oranges, potato, tomato*. Dengan setiap jenis buah dan sayuran terdapat rata-rata train

1312.17 dan *test* 481.29 jenis gambar. Jumlah total keseluruhan terdapat 30357 gambar yang mana terdiri dari *fresh* 14.445 dan *rotten* 15.912.

Pada Tahun 2024, penelitian yang dilakukan oleh Munfaati dan timnya menunjukkan bahwa penerapan CNN dapat mencapai akurasi validasi sebesar 94,21% dan akurasi pengujian 80,83% dengan dataset berisi 12.220 citra **(Munfaati & Witanti, 2024)**. Hal ini membuktikan kemampuan CNN untuk membantu memisahkan buah segar dari busuk dengan tingkat akurasi yang tinggi. Menurut Arinal Haq dan kawan-kawan CNN untuk mengklasifikasikan kematangan buah pisang berdasarkan warna sangat efektif daripada penilaian manusia yang tidak konsisten. Menggunakan VGG-19 dan dilatih menggunakan *optimizer* Adam dan SGD menunjukkan akurasi 100% dan loss terendah 0.02 pada adam 0.04 pada SGD **(Haq & Kurniawan, 2024)**. Dengan solusi ini, teknologi berbasis CNN dapat menjadi alternatif andalan bagi pelaku industri untuk meningkatkan efisiensi proses distribusi dan menjaga kualitas produk. Pendekatan ini juga memiliki potensi luas untuk diterapkan di sektor pertanian dan logistik.

2. METODOLOGI

Metode yang digunakan dalam penelitian ini adalah metode *deep learning* yang bertujuan untuk mengembangkan model kustom berbasis *Convolutional Neural Network* (CNN) yang digunakan mengklasifikasikan buah dan sayuran segar maupun busuk. Model ini dirancang menggunakan arsitektur ResNet-18 sebagai *feature extractor* utama yang dimodifikasi untuk tugas klasifikasi *multi-level*. Adapun tahapan penelitian berbasis *Convolutional Neural Network* (CNN) pada penelitian ini seperti gambar 1.



Gambar 1. Tahap Penelitian

2.1. Data Collection


Pada penelitian ini menggunakan dataset *Fresh and Rotten* yang diunduh dari Kaggle Dataset **(Nayak, 2023)**. Data terdiri dari data *train* dan *test*. Data *train* memiliki jumlah data 23619. Data *test* 6738 gambar.

Table 1. Dataset Fresh And Rotten

No.	Class	Train		Test	
		Fresh	Rotten	Fresh	Rotten
1	<i>apples</i>	2424	3248	791	988
2	<i>banana</i>	2468	2932	892	900
3	<i>bittergroud</i>	327	357	x	x
4	<i>capsicum</i>	990	901	x	x
5	<i>cucumber</i>	496	421	279	255
6	<i>okra</i>	635	338	370	224
7	<i>oranges</i>	1466	1595	388	403
8	<i>potato</i>	536	802	270	370
9	<i>tomato</i>	1858	1825	255	353
Total		11200	12419	3245	3493
		23619		6738	


2.2. Pre-Processing Data

Langkah *pre-processing* dilakukan untuk mengatur kumpulan data yang dipilih ke dalam bentuk yang dapat dikelola untuk fase selanjutnya (**Kusuma, dkk, 2022**). Setiap gambar diubah ukurannya menjadi 224x224 piksel untuk memenuhi persyaratan input model CNN. Pada data *training*, *augmentasi* diterapkan untuk meningkatkan variasi data dan kemampuan generalisasi model, termasuk *random horizontal flip*, *Gaussian blur*, dan penyesuaian ketajaman. Semua gambar dinormalisasi agar memiliki distribusi nilai yang seragam, mempercepat konvergensi model selama pelatihan. Tahapan *pre-processing* seperti pada Gambar 2.

**Gambar 2. Tahap Pre-Processing**

2.3. Perancangan *Arsitektur Customize CNN*

Model CNN yang dirancang dalam penelitian ini memiliki tiga blok utama selain *backbone* ResNet-18. ResNet-18 digunakan sebagai fitur ekstraktor karena telah dilatih pada *dataset ImageNet*, sehingga mampu menangkap fitur visual yang kompleks seperti tekstur dan warna (Agustina, 2024). Sebagian besar parameter pada ResNet-18 dibekukan untuk mengurangi beban komputasi, kecuali 15 lapisan terakhir yang tetap dapat dilatih untuk menyesuaikan dengan *dataset* yang digunakan. Setelah keluaran dari ResNet-18 diperoleh, fitur-fitur tersebut diproses lebih lanjut oleh Blok 1, yang berfungsi mengurangi dimensi fitur secara bertahap dari 512 menjadi 128 menggunakan lapisan linear, aktivasi ReLU, dan *dropout* untuk meningkatkan kemampuan generalisasi model, seperti pada contoh penelitian oleh Zhonglu Lei dan rekanya pada Gambar 3.



Gambar 3. ResNet-18 Model Structure (Lei et al., 2022).

Setelah melalui Blok 1, data diproses oleh dua cabang paralel: Blok 2 dan Blok 3. Blok 2, atau *Fruit Classification Block*, bertugas mengklasifikasikan jenis buah atau sayuran ke dalam 9 kelas, sedangkan Blok 3, atau *Freshness Classification Block*, digunakan untuk menentukan tingkat kesegaran buah atau sayuran ke dalam dua kategori, yaitu *Fresh* (Segar) dan *Rotten* (Busuk). Kedua blok ini menggunakan kombinasi lapisan linear, aktivasi ReLU, dan *dropout*. Untuk menghitung kesalahan prediksi, digunakan fungsi *loss* gabungan yang mengkombinasikan *Cross Entropy Loss* pada Persamaan (1) untuk masing-masing tugas klasifikasi. Rumus fungsi *loss* adalah sebagai berikut:

$$CrossEntropyLoss \Rightarrow \mathcal{L} = \alpha \cdot \mathcal{L}_{fruit} + (1 - \alpha) \cdot \mathcal{L}_{fresh} \quad (1)$$

$$Resnet - 18 \text{ dan blok } 1 \Rightarrow lr = 1 \times 10^{-5} \text{ dan } lr = 3 \times 10^{-4} \quad (2)$$

$$Blok 2 \text{ dan Block } 3 \Rightarrow lr = 3 \times 10^{-4} \quad (3)$$

dengan $\alpha/\alpha = 0.7$ untuk memberikan bobot lebih besar pada tugas klasifikasi jenis buah.

Model dioptimalkan menggunakan tiga optimizer Adam dengan pengaturan *learning rate* yang berbeda untuk setiap bagian. Persamaan (2) ResNet-18 dan Blok 1 menggunakan *learning rate* 1×10^{-5} untuk *backbone* dan 3×10^{-4} untuk Blok 1. Sementara itu, Persamaan (3) Blok 2 dan Blok 3 masing-masing menggunakan *learning rate* sebesar 3×10^{-4} . Kombinasi arsitektur ini dirancang untuk mengintegrasikan kemampuan klasifikasi jenis buah dan tingkat kesegaran secara bersamaan, dengan tetap mempertahankan efisiensi komputasi dan akurasi yang tinggi.

2.4. Pelatihan Model

Pada tahap pelatihan, model ini dilatih untuk menyelesaikan dua tugas secara bersamaan, yaitu klasifikasi jenis buah dan sayuran, serta klasifikasi tingkat *fresh* atau *rotten*. *Dataset* dibagi menjadi data pelatihan dan validasi, dengan preprocessing yang meliputi *resize* gambar, augmentasi data seperti *horizontal flip* dan *Gaussian blur*, dan normalisasi.

Optimisasi dilakukan dengan algoritma Adam pada beberapa blok model, menggunakan *learning rate* berbeda untuk backbone dan lapisan yang ditambahkan. Selama pelatihan, *loss* dihitung menggunakan kombinasi *Cross Entropy Loss* untuk kedua tugas klasifikasi, yang ditimbang menggunakan parameter alpha. Proses ini dievaluasi pada setiap *epoch* dengan menghitung akurasi untuk kedua tugas menggunakan *batch* dari data pelatihan.

2.5. Pengujian Model

Pengujian model dilakukan untuk mengevaluasi kinerja model yang telah dilatih menggunakan *dataset train*. Pengujian ini dirancang untuk menganalisis kemampuan model dalam memprediksi dua cabang keluaran utama, yaitu klasifikasi jenis buah atau sayuran berjumlah 9 kelas dan tingkat kesegaran berjumlah 2 kelas. Proses pengujian mencakup beberapa skenario untuk memastikan evaluasi yang komprehensif terhadap model, dalam model ini terdapat 3 skenario pengujian akan dilakukan dengan cara:

1. **Confusion Matrix:** Model dievaluasi menggunakan *confusion matrix* untuk menganalisis distribusi prediksi, mengidentifikasi prediksi benar (nilai diagonal) dan kesalahan prediksi (nilai non-diagonal).
2. **Visualisasi Prediksi:** Beberapa sampel dari *dataset* validasi divisualisasikan, menampilkan nama buah yang diprediksi, tingkat kesegarannya, dan persentase kesegaran sebagai indikasi tambahan.
3. **Matrik Evaluasi:** Performanya diukur secara kuantitatif menggunakan metrik seperti akurasi, *precision*, *recall*, dan *F1-score*.

2.6. Evaluasi

Evaluasi model dilakukan dengan menghitung beberapa metrik performa, seperti *precision*, *recall*, *F1-score*, dan akurasi, menggunakan fungsi "*classification_report*" dari pustaka "*scikit-learn*". Untuk tugas klasifikasi jenis buah dan sayuran, evaluasi dilakukan terhadap 9 kelas dengan label yang telah diubah dari format *Label Encoder* menjadi nama kelas yang mudah dipahami. Sementara itu, untuk klasifikasi tingkat kesegaran, evaluasi difokuskan pada dua kategori, yaitu *Fresh* dan *Spoiled*.

Selain itu, visualisasi *confusion matrix* digunakan untuk menganalisis lebih lanjut distribusi prediksi model. Di dalam *confusion matrix* terdapat prediksi dan nilai aktual ditampilkan untuk menentukan keakuratan setiap metode (Kusuma, dkk, 2022). Ada beberapa jenis dalam *confusion matrix* yaitu *accuracy*, *precision*, *recall*, dan *F-Score*. Pada Persamaan (4) *Accuracy*, merupakan rasio prediksi yang benar untuk data keseluruhan. Persamaan (5) *Precision*, adalah perbandingan nilai prediksi benar positif dengan hasil total prediksi positif. Persamaan (6) *Recall* adalah perbandingan nilai prediksi positif benar dengan semua data positif benar (Ridhovan, & Suharso, 2022). Persamaan (7) *F-Score* (F1) merupakan rata-rata *harmonic* antara nilai presisi dan *recall* (Ichwan & Syifa, 2023).

$$Accuracy = (N \text{ benar})/N \times 100\% \quad (4)$$

$$Precision = TP/(TP + FP) \quad (5)$$

$$Recall = TP / (TP + FN) \quad (6)$$


$$F1 - Score = 2x (Recall \times Precision) / (Recall + Precision) \quad (7)$$

Model juga diuji pada gambar individual yang diproses dengan *pipeline* transformasi yang sama seperti saat pelatihan. Gambar uji diolah untuk menghasilkan prediksi nama buah atau sayuran dan tingkat kesegarannya, yang kemudian dibandingkan dengan label sebenarnya untuk memastikan akurasi pada skenario dunia nyata.

3. HASIL DAN PEMBAHASAN

3.1. Dataset dan Pre-Processing Data

Dataset yang digunakan merupakan hasil pengumpulan data yang dilakukan oleh **(Nayak, 2023)** dengan tujuan untuk mengklasifikasi buah dan sayuran tidak hanya berdasarkan jenisnya tetapi juga tingkat kesegarannya. Kumpulan data ini terdiri dari 30357 citra sayur dan buah dari data train dan test yang berjumlah 18 kelas. Gambar 4 menunjukkan sampel citra dataset per kelas.



Gambar 4. Sampel Citra Dataset Per Kelas

3.1.1 Augmentasi Data

Tahap berikutnya melakukan augmentasi data untuk meningkatkan jumlah data yang digunakan dengan memperbanyak variasi data agar data citra yang digunakan sesuai dengan standar kriteria model arsitektur yang akan dibangun **(Pratits, dkk, 2023)**. Augmentasi data digunakan untuk meningkatkan variasi *dataset* guna membantu model mengenali pola yang lebih beragam. Teknik augmentasi diterapkan seperti *random horizontal flip* yang membalik gambar secara horizontal dengan probabilitas 0.5, membantu model mengenali objek dalam orientasi yang berbeda. Selain itu, *Gaussian Blur* menambahkan efek kabur pada gambar dengan kernel 3x3 dan tingkat keacakan sigma dalam rentang 0.1 hingga 2.0, yang mensimulasikan kondisi gambar buram sehingga model menjadi lebih tangguh terhadap data berkualitas rendah.

Transformasi lain adalah *random adjust sharpness*, yang menyesuaikan ketajaman gambar dengan kekuatan sebesar 3 dan probabilitas 0.5, memberikan simulasi variasi visual terkait detail pada gambar. Dengan mengkombinasikan transformasi ini, model dilatih dengan data yang lebih variatif, sehingga kemampuan generalisasinya terhadap data baru meningkat.

3.1.2 Normalisasi Data

Normalisasi dilakukan untuk memastikan skala nilai piksel gambar seragam, sehingga mempercepat proses pelatihan dan meningkatkan stabilitas model. Pada penelitian ini

normalisasi diterapkan menggunakan *Normalize* yang mengubah nilai piksel gambar menjadi memiliki rata-rata nol dan standar deviasi satu. Normalisasi sangat penting karena nilai piksel asli biasanya berada dalam rentang 0 hingga 255, yang dapat menyebabkan pelatihan tidak stabil jika tidak disesuaikan. Pada tahap pelatihan dan validasi, normalisasi dilakukan bersamaan dengan transformasi lainnya untuk menjaga konsistensi data yang masuk ke model. Dengan normalisasi ini, model dapat belajar lebih efisien, menghindari masalah seperti exploding atau *vanishing gradients* akibat skala nilai yang tidak seragam, sehingga meningkatkan kinerja model pada proses validasi dan pengujian.

3.3. Pelatihan Model


Pelatihan model dilakukan menggunakan metode pembelajaran multi tugas, di mana model mengoptimalkan dua jenis klasifikasi secara simultan. Sedangkan menurut Nur Fadlia dan Rifki Kosasih dalam penelitiannya proses pelatihan dilakukan agar model yang dibuat dapat mengenali objek yang diinginkan (**Fadlia & Kosasih, 2019**). Fungsi *loss* adalah kombinasi bobot dari *Cross Entropy Loss* untuk masing-masing tugas, dengan parameter $\alpha=0.7$ untuk menyeimbangkan kontribusi kedua *loss* tersebut. Model dilatih selama 10 epoch dengan *optimizer* Adam dan berbagai kecepatan pembelajaran untuk lapisan yang berbeda. Hasil pelatihan dapat dilihat pada Tabel 2.

Table 2. Tabel Hasil Pelatihan Model

<i>Epoch</i>	<i>Train Loss</i>	<i>Train Accuracy (Fruit)</i>	<i>Train Accuracy (Fresh)</i>	<i>Val Loss</i>	<i>Val Accuracy (Fruit)</i>	<i>Val Accuracy (Fresh)</i>
0	0.600	79.8%	79.2%	0.175	95.2%	90.2%
1	0.136	96.2%	92.4%	0.107	97.2%	94.0%
2	0.092	97.7%	94.7%	0.082	97.7%	96.1%
3	0.069	98.4%	95.2%	0.064	98.3%	96.2%
4	0.051	99.0%	96.4%	0.055	98.5%	97.1%
5	0.040	99.3%	97.1%	0.048	98.9%	96.3%
6	0.036	99.3%	97.4%	0.050	99.4%	95.7%
7	0.028	99.6%	97.7%	0.036	99.2%	97.5%
8	0.023	99.7%	98.2%	0.027	99.4%	97.9%
9	0.023	99.5%	98.4%	0.025	99.5%	98.0%

Tabel 2 menunjukkan *Train Loss* dan *Val Loss* menunjukkan penurunan signifikan selama pelatihan, mengindikasikan bahwa model belajar dengan baik pada data pelatihan dan generalisasi pada data validasi. *Train Loss* dan *Val Loss* menunjukkan penurunan signifikan selama pelatihan, mengindikasikan bahwa model belajar dengan baik pada data pelatihan dan generalisasi pada data validasi. *Val Accuracy (Fruit)* dan *Val Accuracy (Fresh)* menunjukkan hasil evaluasi model pada data validasi. Akurasi yang mendekati hasil pelatihan menunjukkan model tidak mengalami *overfitting*. Hasil ini menunjukkan peningkatan konsisten dalam akurasi dan penurunan nilai loss, baik pada data pelatihan maupun validasi.

Classification of Fresh and Rotten Fruits and Vegetables Using a Customized Convolutional Neural Network



Gambar 5. Visualisasi Kinerja Model

Gambar 5. menunjukkan visualisasi dari kinerja model selama proses pelatihan dan validasi. Proses pelatihan model yang dievaluasi menggunakan metrik utama seperti *loss* dan akurasi untuk masing-masing tugas klasifikasi. Gambar 5. memberikan visualisasi perkembangan kinerja model pada data pelatihan dan validasi selama 10 *epoch*.

Grafik *Loss* pada Gambar 5. menunjukkan nilai *loss* untuk data pelatihan dan validasi. Nilai *Loss* menurun secara konsisten, baik pada pelatihan maupun validasi, yang menandakan bahwa model semakin mampu meminimalkan kesalahan prediksi seiring bertambahnya epoch. Perbedaan kecil antara *loss* pelatihan dan validasi menunjukkan bahwa model tidak mengalami *overfitting*.


Grafik *Fruit Name Accuracy* pada Gambar 5. Menunjukkan akurasi meningkat signifikan pada beberapa *epoch* awal dan kemudian mencapai tingkat mendekati 100%. Akurasi validasi hampir selalu berada dalam kisaran yang sama atau sedikit lebih baik dibanding akurasi pelatihan, menandakan bahwa model bekerja dengan baik pada data yang tidak terlihat.

Grafik *Freshness Accuracy* pada Gambar 5. Menunjukkan pola peningkatannya mirip dengan akurasi nama buah, meskipun terdapat sedikit fluktuasi pada akurasi validasi di tengah-tengah epoch. Namun, model akhirnya mencapai akurasi yang sangat tinggi sampai mendekati 98% pada akhir pelatihan.

3.4. Pengujian Model


Pengujian model dilakukan menggunakan *dataset* validasi untuk menilai kinerja model setelah pelatihan selesai. Model berhasil memprediksi dua cabang keluaran secara paralel yaitu nama buah dan kesegarannya. Selama pengujian, tidak ada proses pembaruan parameter yang dilakukan karena model dalam mode evaluasi. Data yang telah dinormalisasi dimasukkan ke

model, dan hasil keluaran berupa probabilitas untuk masing-masing kelas diproses untuk menghasilkan prediksi final. Proses ini mencakup penghitungan *confusion matrix* untuk kedua klasifikasi sebagai bentuk analisis distribusi kesalahan prediksi.



Gambar 6. *Confusion Matrix* Untuk Klasifikasi Jenis Buah/Sayur (9 Kelas)


Gambar 6 menunjukkan performa model dalam memprediksi setiap kelas, di mana sumbu horizontal merepresentasikan kelas prediksi dan sumbu vertikal merepresentasikan kelas sebenarnya. Nilai diagonal utama menggambarkan prediksi yang benar, sementara nilai di luar diagonal menunjukkan kesalahan prediksi. Matriks ini membantu mengidentifikasi kelas-kelas yang sering salah diprediksi, misalnya jika model sering salah mengklasifikasikan "Tomat" sebagai "Apel".



Gambar 7. *Confusion Matrix* Untuk Klasifikasi Tingkat Kesegaran

Gambar 7 *confusion matrix* menunjukkan kemampuan model membedakan antara buah segar dan busuk. Nilai diagonal utama (957 dan 906) menunjukkan jumlah prediksi benar untuk kategori "*Fresh*" dan "*Spoiled*", sementara nilai non-diagonal (16 dan 17) merepresentasikan kesalahan prediksi untuk kategori "*Fresh*" dan "*Spoiled*". Dengan akurasi sebesar 98%, hasil ini menunjukkan performa tinggi dalam klasifikasi kesegaran.

Classification of Fresh and Rotten Fruits and Vegetables Using a Customized Convolutional Neural Network



Gambar 8. Prediksi Jenis Buah Dan Tingkat Kesegaran

Gambar 8 di atas menampilkan hasil visualisasi prediksi model dalam mengklasifikasikan jenis buah berdasarkan *dataset* yang digunakan. Model ini mampu mengenali berbagai jenis buah, seperti *apples*, *banana*, *bittergourd*, *capsicum*, dan lainnya, dengan menampilkan hasil prediksi dalam label "*Predicted: <nama_buah>*". Untuk setiap kelas buah, beberapa gambar dipilih secara acak dari *dataset* validasi untuk memastikan representasi yang merata. Selain itu, prediksi yang ditampilkan telah disesuaikan dengan label asli jika terjadi kesalahan prediksi untuk keperluan analisis yang lebih mendalam.

Selain klasifikasi jenis buah, model juga memprediksi tingkat kesegaran buah dengan dua kategori, yaitu *Fresh* (Segar) dan *Spoiled* (Busuk), yang disertai persentase tingkat kesegaran sebagai indikasi tambahan. Persentase tersebut menunjukkan seberapa tingkat kesegaran atau kebusukan yang ada dalam gambar. Informasi ini memberikan gambaran tentang kondisi buah secara lebih rinci, yang relevan untuk berbagai aplikasi praktis, seperti sistem inspeksi kualitas makanan atau manajemen rantai pasokan. Hasil ini menunjukkan kemampuan model dalam memadukan klasifikasi visual dengan informasi tambahan tentang kondisi buah.

3.5. Evaluasi

Evaluasi metrik performa yang terdiri dari nilai akurasi, *precision*, *recall*, dan *f1-score* (**Agung Mujiono, Kartini, & Yulia Puspaningrum, 2024**). Laporan klasifikasi yang diberikan menggambarkan kinerja dari model pada 9 kelas berbeda, yaitu *apples*, *banana*, *bittergourd*, *capsicum*, *cucumber*, *okra*, *oranges*, *potato*, *tomato* terdapat pada

Table 3. Klasifikasi Jenis Buah Dan Sayur

Kelas	Precision	Recall	F1-Score	Support
<i>Apples</i>	1.00	1.00	1.00	225
<i>Banana</i>	1.00	1.00	1.00	225
<i>Bittergroud</i>	1.00	1.00	1.00	103
<i>Capsicum</i>	1.00	1.00	1.00	225
<i>Cucumber</i>	0.99	0.98	0.98	218
<i>Okra</i>	0.98	0.98	0.98	225
<i>Oranges</i>	1.00	1.00	1.00	225
<i>Potato</i>	0.99	1.00	1.00	225
<i>Tomato</i>	1.00	1.00	1.00	225
Rata-rata	0.99	0.99	0.99	1896

Table 4. Klasifikasi *Fresh And Spoiled*

Kelas	Precision	Recall	F1-Score	Support
<i>Fresh</i>	0.98	0.98	0.98	973
<i>Spoiled</i>	0.98	0.98	0.98	923
Rata-rata	0.98	0.98	0.98	1896

Pada Tabel 3 klasifikasi buah dan sayur, rata-rata *precision*, *recall*, dan *F1-score* mencapai 0.99, menandakan bahwa model sangat akurat untuk hampir semua kelas. Begitu pula Tabel 4 untuk klasifikasi *fresh and spoiled*, metrik ini menunjukkan hasil konsisten dengan nilai 0.98, memperkuat keefektifan model yang sudah di custom. Nilai *accuracy* model secara keseluruhan adalah 0.98 yang berarti sebesar 98% dari total instansi telah berhasil diklasifikasikan dengan benar oleh model.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan arsitektur *Customize Convolutional Neural Network* (CNN) berbasis ResNet-18 dengan tiga blok tambahan yang mampu melakukan klasifikasi jenis dan tingkat kesegaran buah serta sayuran secara simultan. Model menunjukkan akurasi tinggi, yaitu 99% untuk klasifikasi jenis dan 98% untuk kesegaran. Evaluasi juga menunjukkan bahwa buah atau sayuran dengan kondisi visual membusuk (*rotten*) cenderung lebih sering salah diklasifikasikan jenisnya dibandingkan yang segar (*fresh*). Temuan ini menunjukkan bahwa tingkat kesegaran dapat memengaruhi akurasi pengenalan jenis. Strategi multitugas dan augmentasi data terbukti efektif dalam meningkatkan kinerja model secara keseluruhan. Pendekatan ini berpotensi diterapkan dalam sistem inspeksi kualitas produk hortikultura secara otomatis, efisien, dan adaptif terhadap kondisi nyata di lapangan. Untuk penelitian selanjutnya, disarankan penggunaan data primer yang mencakup variasi kondisi kesegaran agar model lebih terpersonalisasi dan hasil klasifikasi lebih representatif terhadap kondisi nyata.

DAFTAR RUJUKAN

- Agustina, D. A. (2024). Klasifikasi Citra Jenis Kulit Wajah Dengan Algoritma Convolutional Neural Network (CNN) RESNET-50. *Jurnal Riset Sistem Informasi*, 1(3), 01–07.
<https://doi.org/10.69714/13sbbby24>

- Cahya, N. F., Hardi, N., Riana, D., Hadianti, S., Mandiri Jakarta Cipinang Melayu, N., Makasar, K., ... Khusus Ibukota Jakarta, D. (2021). *SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)*. Retrieved from <http://sistemasi.ftik.unisi.ac.id>
- Fadlia, N., & Kosasih, R. (2019). Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Teknologi Dan Rekayasa*, 24(3), 207–215. <https://doi.org/10.35760/tr.2019.v24i3.2397>
- Haq, A. F., & Kurniawan, M. (2024). *Klasifikasi Tingkat Kematangan Buah Pisang Menggunakan Metode Cnn Arsitektur VGG19*.
- Hamidah, S. (2015). Sayuran dan Buah Serta Manfaatnya Bagi Kesehatan. *Fakultas Teknik Universitas Negeri Yogyakarta*, 1–10.
- Ichwan, M., & Siti Syifa, R. (2023). MIND (Multimedia Artificial Intelligent Networking Database Klasifikasi Citra Bibit Tanaman Menggunakan Convolutional Neural Network dan Improved Feature Pyramid Network. *Journal MIND Journal / ISSN*, 8(1), 1–13.
- Kusuma, J., Hayadi, B. H., Wanayumini, & Rosnelly, R. (2022). Komparasi Metode Multi Layer Perceptron (MLP) dan Support Vector Machine (SVM) untuk Klasifikasi Kanker Payudara. *MIND Journal*, 7(1), 51–60. <https://doi.org/10.26760/mindjournal.v7i1.51-60>
- Lei, Z., Li, H., Zhao, J., Jing, L., Tang, Y., & Wang, H. (2022). Individual Tree Species Classification Based on a Hierarchical Convolutional Neural Network and Multitemporal Google Earth Images. *Remote Sensing*, 14(20). <https://doi.org/10.3390/rs14205124>
- Mujiono, A., Kartini, K., & Yulia Puspaningrum, E. (2024). Implementasi Model Hybrid Cnn-Svm Pada Klasifikasi Kondisi Kesegaran Daging Ayam. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(1), 756–763. <https://doi.org/10.36040/jati.v8i1.8855>
- Munfaati, E. A. N., & Witanti, A. (2024). Klasifikasi Buah dan Sayuran Segar atau Busuk Menggunakan Convolutional Neural Network. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 9(1), 27–38. <https://doi.org/10.14421/jiska.2024.9.1.27-38>
- Nayak, S. S. (2023). Fresh and Rotten/Stale Fruits and Vegetables Classification Dataset. Retrieved from Kaggle website: <https://www.kaggle.com/datasets/swoyam2609/fresh-and-stale-classification>
- Pratitis, W. L., Kurniasari, K., & Fata, H. Al. (2023). Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm. *JTECS: Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Power Sistem Dan Komputer*, 3(2), 117. <https://doi.org/10.32503/jtecs.v3i2.3433>

- Prinzky, & Lubis, C. (2022). Klasifikasi Buah Segar Dan Busuk Menggunakan Convolutional Neural Network Berbasis Android. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 10(2), 10823–10827. <https://doi.org/10.24912/jiksi.v10i2.22551>
- Ridhovan, A., & Suharso, A. (2022). Penerapan Metode Residual Network (ResNet) Dalam Klasifikasi Penyakit Pada Daun Gandum. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*. <https://doi.org/https://doi.org/10.29100/jipi.v7i1.2410>
- Sri Rahmadhani, U., & Lysbetti Marpaung, N. (2023). *Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN*. 8(2).
- Zhao, Y., Zhang, X., Feng, W., & Xu, J. (2022). Deep Learning Classification by ResNet-18 Based on the Real Spectral Dataset from Multispectral Remote Sensing Images. *Remote Sensing*, 14(19). <https://doi.org/10.3390/rs14194883>