

Pendeteksian Buah Matang, Mentah, dan Busuk Menggunakan *Convolutional Neural Network*

Akbar Al Fattah, 13522036¹

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132, Indonesia

13522036@std.stei.itb.ac.id

Abstrak— Kematangan buah merupakan faktor penting yang menentukan kualitas, keamanan konsumsi, dan nilai ekonomi produk hortikultura. Penilaian kematangan buah secara konvensional umumnya masih dilakukan melalui pengamatan visual secara manual, yang bersifat subjektif dan kurang konsisten. Oleh karena itu, penelitian ini mengusulkan sistem otomatis untuk mendeteksi tingkat kematangan buah menggunakan pendekatan *Convolutional Neural Network* (CNN) berbasis pengolahan citra digital. Sistem yang dikembangkan mengklasifikasikan citra buah ke dalam tiga kategori, yaitu mentah, matang, dan busuk. Model CNN dibangun dengan pendekatan *transfer learning* menggunakan arsitektur MobileNetV2 yang telah dilatih sebelumnya pada dataset ImageNet sebagai pengekstraksi fitur. Dataset yang digunakan berasal dari Kaggle dan diproses melalui tahapan pra-proses berupa penyesuaian ukuran citra, normalisasi nilai piksel, serta pembagian data pelatihan dan validasi. Hasil pengujian menunjukkan bahwa model mampu mengklasifikasikan tingkat kematangan buah dengan tingkat kepercayaan yang baik, khususnya pada kelas buah matang dan busuk. Meskipun demikian, masih ditemukan beberapa kesalahan prediksi yang disebabkan oleh kemiripan visual antar kelas dan keterbatasan jumlah data. Secara keseluruhan, penelitian ini menunjukkan bahwa metode CNN memiliki potensi yang signifikan dalam mendukung proses klasifikasi kematangan buah secara otomatis dan dapat dikembangkan lebih lanjut untuk aplikasi di bidang pertanian cerdas.

Kata Kunci— *Convolutional Neural Network, Image Processing, MobileNetV2, Transfer Learning*

I. PENDAHULUAN

Buah merupakan komoditas yang memiliki peran penting dalam memenuhi kebutuhan gizi masyarakat. Kualitas buah sangat dipengaruhi oleh tingkat kematangannya, karena kematangan menentukan rasa, tekstur, nilai gizi, serta kelayakan konsumsi. Buah yang masih mentah umumnya memiliki rasa asam dan tekstur keras, sedangkan buah yang terlalu matang atau busuk dapat membahayakan kesehatan apabila dikonsumsi. Oleh

karena itu, proses penentuan kematangan buah menjadi tahapan krusial dalam distribusi, penyimpanan, dan pemasaran produk pertanian.

Pada praktiknya, penilaian kematangan buah masih banyak dilakukan secara manual oleh manusia berdasarkan pengamatan visual, seperti warna kulit, bercak, dan tingkat kerusakan. Metode ini memiliki beberapa kelemahan, di antaranya adalah bersifat subjektif, bergantung pada pengalaman pengamat, memerlukan waktu yang lama, serta sulit diterapkan secara konsisten dalam skala besar. Seiring meningkatnya kebutuhan akan otomatisasi di bidang pertanian dan industri pangan, diperlukan suatu sistem yang mampu melakukan klasifikasi kematangan buah secara cepat, akurat, dan konsisten.

Perkembangan teknologi pengolahan citra digital dan kecerdasan buatan, khususnya *Deep Learning*, menawarkan solusi yang menjanjikan untuk permasalahan tersebut. Salah satu metode *Deep Learning* yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN). CNN memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis, seperti warna, tekstur, dan pola bentuk, sehingga sangat sesuai untuk tugas pengenalan dan klasifikasi objek pada citra digital.

Dalam penelitian ini, CNN dimanfaatkan untuk mengklasifikasikan kematangan buah ke dalam tiga kategori utama, yaitu mentah (*unripe*), matang (*fresh*), dan busuk (*rotten*). Selain proses klasifikasi, sistem ini juga dilengkapi dengan tahap segmentasi citra untuk mendeteksi lebih dari satu buah dalam satu gambar, sehingga hasil yang diperoleh lebih mendekati kondisi nyata.

Untuk meningkatkan performa dan efisiensi pelatihan, penelitian ini menerapkan pendekatan *transfer learning* menggunakan arsitektur MobileNetV2 yang telah dilatih pada dataset ImageNet. Pendekatan ini diharapkan

mampu menghasilkan model dengan akurasi tinggi meskipun jumlah data pelatihan terbatas. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi kematangan buah berbasis pengolahan citra dan *Deep Learning* yang dapat diaplikasikan pada bidang pertanian cerdas (*smart agriculture*).

II. LANDASAN TEORI

A. Kematangan Buah

Kematangan buah merupakan tahapan fisiologis yang menandai kesiapan buah untuk dikonsumsi. Proses ini melibatkan perubahan biologis dan kimia, seperti degradasi klorofil, peningkatan kandungan gula, perubahan tekstur, serta munculnya aroma khas buah matang. Menurut Kader (2002), tingkat kematangan buah sangat menentukan kualitas, daya simpan, dan nilai ekonomi produk hortikultura.

Secara umum, tingkat kematangan buah dapat diklasifikasikan menjadi tiga kategori utama, yaitu mentah (*unripe*), matang (*ripe/fresh*), dan busuk (*rotten*). Buah mentah belum mencapai kualitas optimal untuk dikonsumsi, sedangkan buah busuk mengalami degradasi jaringan akibat aktivitas enzim dan mikroorganisme (Wills et al., 2007). Oleh karena itu, klasifikasi kematangan buah menjadi aspek penting dalam proses sortasi dan pengendalian mutu.

B. Pengolahan Citra Digital

Pengolahan citra digital adalah teknik untuk memproses citra dalam bentuk digital guna mengekstraksi informasi yang relevan. Citra digital direpresentasikan sebagai matriks dua dimensi yang terdiri dari piksel-piksel dengan nilai intensitas tertentu (Gonzalez & Woods, 2018).

Dalam konteks penelitian ini, pengolahan citra digital digunakan untuk:

1. Membaca dan menampilkan citra buah,
2. Melakukan praproses citra sebelum diklasifikasikan,
3. Menyajikan hasil klasifikasi dalam bentuk visual.

Pengolahan citra digital memungkinkan sistem komputer meniru kemampuan penglihatan manusia secara otomatis dan konsisten.

C. Praproses Citra

Praproses citra bertujuan untuk meningkatkan kualitas citra dan menyesuaikan format input agar sesuai dengan

kebutuhan model. Menurut Jain (1989), praproses citra berfungsi untuk mengurangi variasi yang tidak relevan dan meningkatkan performa sistem pengenalan pola.

Pada penelitian ini, praproses citra meliputi:

- *Resizing* citra menjadi 224×224 piksel,
- Normalisasi nilai piksel ke rentang [0,1],
- Penyesuaian dimensi citra menjadi bentuk batch sebelum dimasukkan ke model.

Tahapan ini penting untuk memastikan keseragaman input dan kestabilan proses pelatihan serta inferensi model CNN.

D. *Machine Learning* dan *Deep Learning*

Machine Learning merupakan cabang kecerdasan buatan yang memungkinkan sistem komputer belajar dari data dan meningkatkan kinerjanya tanpa diprogram secara eksplisit. *Deep Learning* adalah subbidang dari *Machine Learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk mempelajari representasi data yang kompleks (Goodfellow et al., 2016).

Deep Learning sangat efektif dalam pengolahan citra karena mampu mempelajari fitur visual secara otomatis, mulai dari fitur sederhana seperti tepi hingga fitur kompleks seperti bentuk dan tekstur objek.

E. *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) adalah arsitektur jaringan saraf tiruan yang dirancang khusus untuk pemrosesan data citra. CNN menggunakan operasi konvolusi untuk mengekstraksi fitur lokal dari citra input. Menurut LeCun et al. (1998), CNN merupakan metode yang sangat efektif dalam pengenalan pola visual.

CNN terdiri dari beberapa komponen utama, yaitu:

1. *Convolutional Layer*, untuk mengekstraksi fitur visual,
2. *Activation Function (ReLU)*, untuk menambahkan sifat non-linear,
3. *Pooling Layer*, untuk mereduksi dimensi fitur,
4. *Fully Connected Layer*, untuk melakukan klasifikasi.

Dalam penelitian ini, CNN digunakan untuk mengklasifikasikan citra buah ke dalam tiga kelas

kematangan berdasarkan pola visual yang dipelajari selama proses pelatihan.

F. Transfer Learning

Transfer learning adalah teknik pembelajaran mesin yang memanfaatkan model yang telah dilatih pada dataset besar untuk menyelesaikan tugas baru yang serupa. Pendekatan ini sangat efektif ketika jumlah data pelatihan terbatas (Pan & Yang, 2010).

Pada penelitian ini digunakan arsitektur MobileNetV2, yaitu model CNN ringan yang telah dilatih pada dataset ImageNet. Lapisan dasar MobileNetV2 dibekukan (*frozen*) sehingga hanya lapisan klasifikasi tambahan yang dilatih. Menurut Sandler et al. (2018), MobileNetV2 dirancang untuk efisiensi komputasi dengan tetap mempertahankan akurasi yang baik.

G. Data Augmentation

Data augmentation merupakan teknik untuk meningkatkan variasi data pelatihan dengan melakukan transformasi pada citra, seperti rotasi, pergeseran, dan perubahan skala. Teknik ini bertujuan untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting* (Shorten & Khoshgoftaar, 2019).

Pada implementasi ini, data augmentation diterapkan secara sederhana menggunakan normalisasi dan pembagian data pelatihan dan validasi melalui *ImageDataGenerator* dari Keras.

H. Klasifikasi Multikelas

Klasifikasi multikelas adalah proses pengelompokan data ke dalam lebih dari dua kelas. Pada penelitian ini, klasifikasi dilakukan terhadap tiga kelas kematangan buah, yaitu mentah, matang, dan busuk. Model CNN menghasilkan probabilitas untuk setiap kelas menggunakan fungsi aktivasi *softmax*, sehingga kelas dengan probabilitas tertinggi dipilih sebagai hasil prediksi.

Pendekatan ini memungkinkan sistem memberikan tidak hanya label kelas, tetapi juga tingkat kepercayaan (*confidence score*) dari hasil klasifikasi.

I. Evaluasi

Evaluasi performa model dilakukan untuk mengetahui kemampuan model dalam mengklasifikasikan data dengan benar. Metrik utama yang digunakan adalah **akurasi**, yaitu

perbandingan antara jumlah prediksi yang benar dengan total data. Selain itu, proses pelatihan juga dianalisis menggunakan data validasi untuk mengamati kestabilan pembelajaran model (Chollet, 2018).

III. IMPLEMENTASI

A. Exploratory Data Analysis

Dataset yang digunakan untuk eksperimen ini dapat diakses pada pranala berikut:

<https://www.kaggle.com/datasets/leftin/fruit-ripeness-unripe-ripe-and-rotten>

Dari hasil eksplorasi data, didapatkan jumlah gambar untuk setiap label sebagai berikut.

1. Matang: 4740 gambar
2. Mentah: 5316 gambar
3. Busuk: 6161 gambar

```
=====
FRUIT RIPENESS DETECTOR - CNN (FIXED)
=====
1. Training
2. Detection
Pilih (1/2): 1
✓ Dataset ditemukan di: /kaggle/input/fruit-ripeness-unripe-ripe-and-rotten
=====
SETUP DATASET
=====
Jumlah data:
  fresh: 4740
  unripe: 5316
  rotten: 6161
Found 12285 images belonging to 3 classes.
Found 3070 images belonging to 3 classes.
✓ class indices dismapan: {'fresh': 0, 'rotten': 1, 'unripe': 2}
/usr/local/lib/python3.12/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter.py:121: UserWarning: Your
self._warn_if_super_not_called()
```

Gambar 1.1: Hasil EDA dataset

B. Konfigurasi Model

Berikut ini adalah konfigurasi model yang digunakan saat melakukan pelatihan model menggunakan dataset yang digunakan.

Parameter	Nilai
Ukuran citra input	224 × 224
Batch size	32
Jumlah epoch	10
Optimizer	Adam
Learning rate	Default (Adam)
Loss function	Categorical Crossentropy
Metrik evaluasi	Accuracy
Validation split	20%

Tabel 2.1: Konfigurasi model yang digunakan

C. Arsitektur Model

Model yang digunakan dalam penelitian ini menerapkan pendekatan *transfer learning* dengan memanfaatkan arsitektur MobileNetV2 sebagai *base model*. MobileNetV2 dipilih karena memiliki efisiensi komputasi yang tinggi serta performa yang baik dalam tugas klasifikasi citra, khususnya pada perangkat dengan sumber daya terbatas.

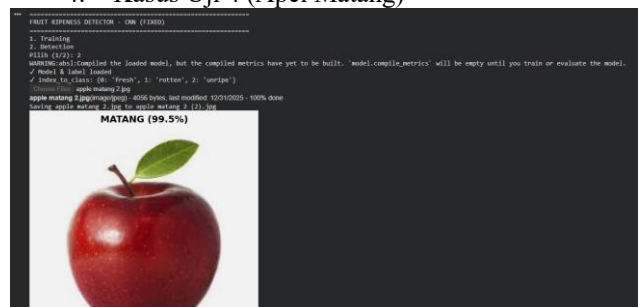
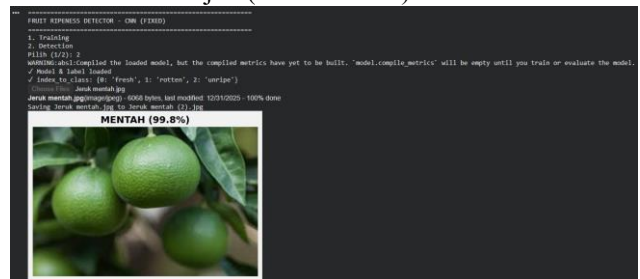
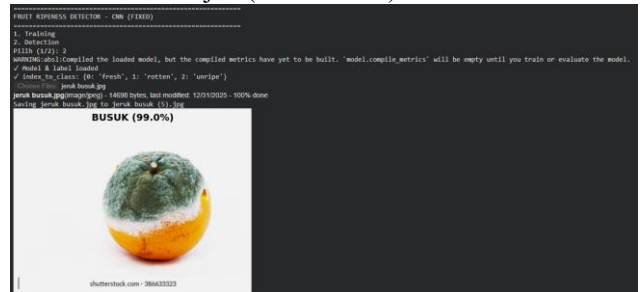
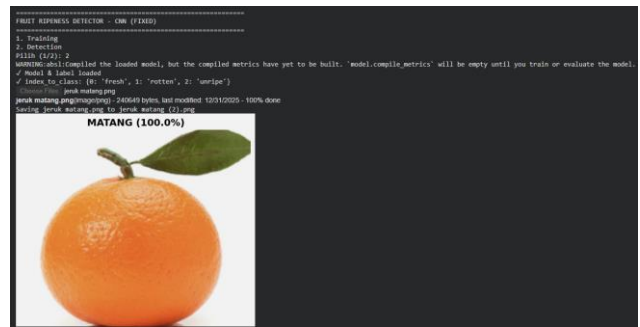
Lapisan dasar MobileNetV2 dikonfigurasi dengan ukuran masukan sebesar 224 × 224 × 3 piksel dan menggunakan bobot hasil pelatihan pada dataset ImageNet. Pengaturan `include_top=False` dilakukan untuk menghilangkan lapisan klasifikasi bawaan

Keluaran dari MobileNetV2 selanjutnya diteruskan ke lapisan Global Average Pooling 2D. Lapisan ini berfungsi untuk mereduksi dimensi fitur dengan menghitung nilai rata-rata dari setiap peta fitur (*feature map*). Penggunaan *global average pooling* mampu mengurangi jumlah parameter model dibandingkan penggunaan *fully connected layer* konvensional, sekaligus meningkatkan kemampuan generalisasi model.

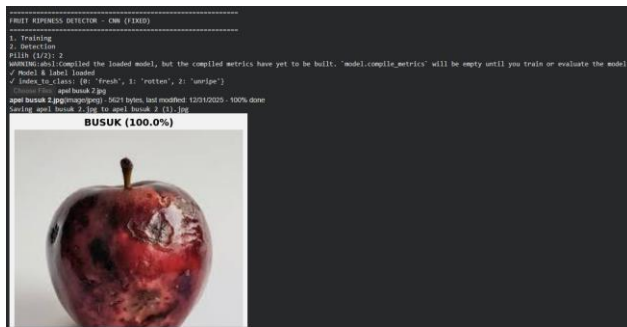
Selanjutnya, diterapkan Dropout dengan tingkat 0,5, yang bertujuan untuk mengurangi *overfitting* dengan cara menonaktifkan sebagian neuron secara acak selama proses pelatihan. Teknik ini membantu model agar tidak terlalu bergantung pada neuron tertentu dan meningkatkan kemampuan generalisasi terhadap data baru.

Secara keseluruhan, model dikompilasi menggunakan optimizer Adam, fungsi *loss categorical_crossentropy* yang sesuai untuk permasalahan klasifikasi multikelas, serta metrik evaluasi berupa akurasi. Kombinasi arsitektur dan konfigurasi ini dirancang untuk menghasilkan model yang efisien, stabil, dan memiliki performa yang baik dalam mengklasifikasikan kematangan buah berdasarkan citra digital.

1. Kasus Uji 1 (Jeruk matang)



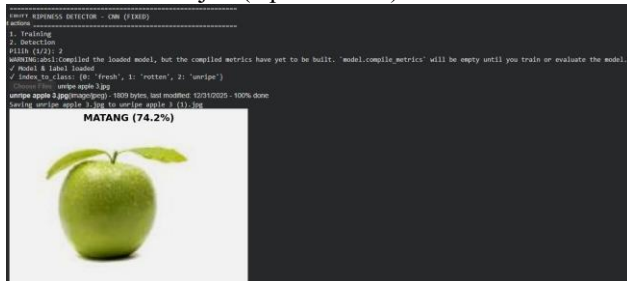
5. Kasus Uji 5 (Apel Busuk)



Hasil prediksi: Busuk

Confidence:100%

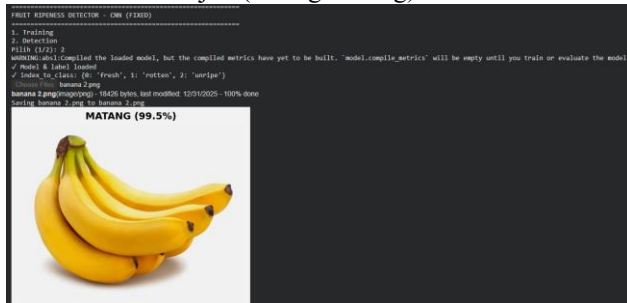
6. Kasus Uji 6 (Apel Mentah)



Hasil prediksi: Matang

Confidence:74,2%

7. Kasus Uji 7 (Pisang matang)



Hasil prediksi: Matang

Confidence: 99,5%

8. Kasus Uji 8 (Pisang Mentah)



Hasil prediksi: Mentah

Confidence: 77,3%

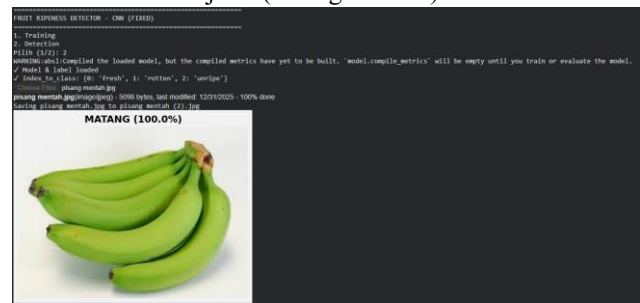
9. Kasus Uji 9 (Pisang Busuk)



Hasil prediksi: Busuk

Confidence: 99,8%


10. Kasus Uji 10 (Pisang Mentah)



Hasil prediksi: Matang

Confidence: 100%

11. Kasus Uji 11 (Jruk Matang)



Hasil prediksi: Busuk

Confidence: 83,0%

V. ANALISIS

Berdasarkan hasil dari pengujian yang didapatkan, ada beberapa kasus dimana model berhasil memprediksi kematangan buah dengan benar dan ada beberapa kasus dimana model salah memprediksi kematangan buah. Salah satu penyebab dari kesalahan prediksi yang terjadi adalah ternyata pada dataset Kaggle yang digunakan, penampilan warna dari buah pisang yang mentah dan matang memiliki kemiripan, dan buah jeruk matang dan busuk memiliki kemiripan dari warna. Hal ini yang mungkin membuat hasil prediksi menjadi tidak akurat.

VI. KESIMPULAN

Kesimpulan yang dapat ditarik dari hasil eksperimen ini adalah model CNN sudah mampu untuk mendeteksi kematangan buah. Namun, untuk memperbaiki model, diperlukan perbaikan dataset lebih lanjut dengan pemberian label yang benar, menyeimbangkan jumlah data gambar buah, dan mengubah konfigurasi model yang lebih baik

REFERENSI

- Chollet, F. (2018). Deep Learning with Python. Manning Publications.
- Gonzalez, R. C., & Woods, R. E. (2018). Digital Image Processing. Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- Jain, A. K. (1989). Fundamentals of Digital Image Processing. Prentice Hall.

Kader, A. A. (2002). Postharvest Technology of Horticultural Crops. University of California.
LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition.
Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering.
Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks.
Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning.
Wills, R., McGlasson, B., Graham, D., & Joyce, D. (2007). Postharvest: An Introduction to the Physiology and Handling of Fruit, Vegetables and Ornamentals.

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 31 Desember 2025



Akbar Al Fattah
13522036