

## Klasifikasi Citra Buah Apel Multikelas Menggunakan Transfer Learning dan Implementasi Inferensi Berbasis Web

Sri Aryanti<sup>1</sup>, Gustam Efendi<sup>2</sup>, Yanti Setiyowati<sup>3</sup>, Charles Butar Butar<sup>4</sup>, Hendriyanto<sup>5</sup>

<sup>1,2,3</sup> Program Studi Sistem Informasi, Sekolah Tinggi Teknologi Bina Tunggal

<sup>1,2,3</sup> Jl. Wahab Affan No.1, Medan Satria, Kota Bekasi, Jawa Barat 17132, Indonesia

<sup>4,5</sup> Program Studi Sistem Informasi, Sekolah Tinggi Manajemen Informatika dan Komputer Pranata Indonesia

<sup>5,6</sup> Jl. Pengasinan Tengah No.100, Kec. Rawalumbu, Kota Bekasi, Jawa Barat 17115, Indonesia

<sup>1</sup> [srti.aryanti@student.stt-binatunggal.ac.id](mailto:srti.aryanti@student.stt-binatunggal.ac.id)

<sup>2</sup> [gustam.efendi@stt-binatunggal.ac.id](mailto:gustam.efendi@stt-binatunggal.ac.id)

<sup>3</sup> [yanti@stt-binatunggal.ac.id](mailto:yanti@stt-binatunggal.ac.id)

<sup>4</sup> [charles.butarbutar@pranataindonesia.ac.id](mailto:charles.butarbutar@pranataindonesia.ac.id)

<sup>5</sup> [hendriyanto@pranataindonesia.ac.id](mailto:hendriyanto@pranataindonesia.ac.id)

### INFORMASI ARTIKEL

diajukan : 10-09-2025  
revisi : 19-12-2025  
diterima : 13-12-2025  
dipublish : 31-12-2025

### ABSTRAK

Pesatnya perkembangan teknologi kecerdasan buatan membuka peluang besar dalam modernisasi sektor hortikultura, khususnya pada otomatisasi identifikasi komoditas. Penelitian ini bertujuan untuk mengintegrasikan metode transfer learning ke dalam sistem klasifikasi citra buah apel multikelas yang terhubung dengan layanan inferensi berbasis web. Permasalahan utama yang diangkat adalah ketergantungan Industri pada proses identifikasi varietas secara konvensional yang memiliki risiko tinggi terhadap subjektivitas manusia, inefisiensi waktu, dan kesalahan penentuan jenis. Metodologi penelitian ini menerapkan pendekatan deep learning dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) melalui teknik transfer learning untuk mengenali enam varietas apel unggulan. Pengembangan sistem dilakukan dengan membangun antarmuka web menggunakan bahasa pemrograman PHP yang berfungsi menjembatani pengguna dengan model prediktif melalui Hugging Face Inference API. Mekanisme ini memungkinkan pemrosesan data citra dilakukan secara real-time tanpa memerlukan komputasi lokal yang berat. Hasil pengujian menunjukkan bahwa penggabungan model pembelajaran mendalam dengan infrastruktur berbasis cloud mampu menghasilkan sistem klasifikasi yang tidak hanya memiliki tingkat akurasi tinggi, tetapi juga menawarkan kemudahan akses bagi pengguna akhir. Implementasi ini diharapkan dapat menjadi prototipe bagi sistem penyortiran buah otomatis yang lebih efisien dan reliabel di masa depan.

*Kata kunci : Deep Learning; CNN; Transfer Learning; Klasifikasi Buah; Hugging Face API.*

## PENDAHULUAN

Perkembangan kecerdasan buatan, khususnya *deep learning*, telah meningkatkan kemampuan pengolahan citra digital secara signifikan. Arsitektur Convolutional Neural Network (CNN) mampu mengekstraksi fitur visual seperti warna, tekstur, dan bentuk objek secara otomatis dengan akurasi tinggi (LeCun et al., 2015). Teknologi ini mulai banyak diterapkan pada sektor pertanian modern untuk membantu proses identifikasi dan penyortiran produk hortikultura secara lebih efisien.

Apel merupakan komoditas hortikultura bernilai ekonomi tinggi yang memiliki berbagai varietas, seperti Braeburn, Crimson Snow, Golden, Granny Smith, Pink Lady, dan Red Delicious. Setiap varietas memiliki karakteristik visual berbeda, namun proses identifikasi di lapangan masih dilakukan secara manual oleh pekerja sortir atau pedagang. Metode ini memerlukan waktu lama serta rentan terhadap kesalahan akibat subjektivitas dan kelelahan manusia (Silva & Patel, 2021). Oleh karena itu diperlukan sistem otomatis yang mampu melakukan klasifikasi varietas apel secara cepat dan konsisten.

Pendekatan *transfer learning* memungkinkan model CNN yang telah dilatih pada dataset besar seperti ImageNet digunakan kembali untuk tugas spesifik dengan kebutuhan data dan waktu pelatihan yang lebih kecil (Pan & Yang, 2010). Beberapa arsitektur modern, antara lain ResNet dan Vision Transformer, menunjukkan performa tinggi dalam klasifikasi citra (Dosovitskiy et al., 2021). Selain akurasi model, aspek implementasi juga penting agar sistem dapat digunakan

secara praktis. Teknologi *cloud inference* memungkinkan proses prediksi dilakukan pada server sehingga pengguna cukup mengunggah citra melalui antarmuka web. Platform seperti Hugging Face menyediakan layanan inferensi yang mudah diintegrasikan dan mampu memberikan hasil secara *real-time* (Wolf et al., 2020).

Sebagian penelitian sebelumnya hanya berfokus pada pembuatan model klasifikasi tanpa implementasi aplikasi yang dapat digunakan langsung oleh pengguna, atau terbatas pada klasifikasi buah tunggal dan berjalan secara *offline*. Kondisi ini menunjukkan adanya kesenjangan antara penelitian akademik dan pemanfaatan praktis di lapangan.

Berdasarkan hal tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi citra buah apel multikelas menggunakan metode *transfer learning* serta mengintegrasikannya ke dalam aplikasi berbasis web dengan layanan inferensi. Penelitian difokuskan pada enam varietas apel dan mengevaluasi performa model menggunakan metrik klasifikasi serta waktu respons sistem.

## TEORI

### Sistem Pakar

Sistem pakar adalah cabang dari kecerdasan buatan (*Artificial Intelligence*) yang mengadopsi pengetahuan manusia ke dalam komputer untuk menyelesaikan masalah pada domain spesifik yang biasanya memerlukan keahlian pakar. Dalam konteks klasifikasi objek visual, sistem pakar berfungsi sebagai pengambil keputusan berdasarkan fitur yang diekstraksi oleh model pembelajaran mesin

(Giarratano & Riley, 2005). Implementasi sistem ini pada platform digital memungkinkan proses identifikasi yang konsisten, cepat, dan dapat diakses secara luas tanpa keterbatasan fisik seorang pakar manusia (Luger, 2005).

### Representasi Pengetahuan

Representasi pengetahuan merupakan metode pengorganisasian informasi dan fakta ke dalam format yang dapat diproses oleh mesin untuk melakukan penalaran. Pada sistem klasifikasi citra berbasis *Deep Learning*, pengetahuan tidak lagi direpresentasikan secara manual melalui aturan *if-then* yang kaku, melainkan melalui arsitektur jaringan saraf yang menyimpan bobot (*weights*) dan fitur hierarkis dari dataset (LeCun et al., 2015). Representasi ini mencakup pola visual mulai dari tepi objek hingga tekstur kompleks yang menentukan klasifikasi akhir suatu varietas (Goodfellow et al., 2016).

### Mesin Inferensi (*Inference Engine*)

Mesin inferensi adalah komponen inti dari sistem pakar yang berfungsi sebagai unit penalaran untuk mengolah pengetahuan yang tersimpan guna menghasilkan kesimpulan atau keputusan. Dalam sistem berbasis API seperti Hugging Face, mesin inferensi bekerja dengan menerima input data (gambar), melakukan perhitungan *forward pass* melalui lapisan model, dan memberikan hasil prediksi berupa nilai probabilitas (Wolf et al., 2020). Proses ini memastikan bahwa input pengguna dipetakan secara akurat ke dalam kelas yang sesuai berdasarkan basis pengetahuan yang telah dilatih sebelumnya.

### Mekanisme Probabilistik

Mekanisme probabilistik digunakan untuk menangani ketidakpastian dalam proses pengambilan keputusan. Pada model klasifikasi citra, keluaran sistem biasanya berupa fungsi *Softmax* yang memberikan skor kepercayaan (*confidence score*) untuk setiap kelas dalam rentang 0 hingga 1 (Goodfellow et al., 2016). Pendekatan ini memungkinkan sistem untuk tidak hanya memberikan satu label kaku, tetapi juga menunjukkan tingkat keyakinan model terhadap klasifikasi tersebut, yang sangat krusial dalam membedakan varietas dengan kemiripan visual yang tinggi (Hameed et al., 2020).

## METODOLOGI

Penelitian ini menggunakan pendekatan rekayasa perangkat lunak dan *machine learning* untuk mengembangkan sistem klasifikasi citra buah apel multikelas berbasis *transfer learning* yang terintegrasi dengan aplikasi web. Tahapan penelitian meliputi studi literatur, pengumpulan data, pra-proses citra, pelatihan model, evaluasi performa, serta implementasi sistem.

### Dataset dan Pra-proses

Dataset berupa citra enam varietas apel (Braeburn, Crimson Snow, Golden, Granny Smith, Pink Lady, dan Red Delicious). Seluruh citra diseragamkan ukurannya, kemudian dilakukan *normalization* dan augmentasi data (rotasi, flipping, dan perubahan pencahayaan) untuk meningkatkan kemampuan generalisasi model. Dataset dibagi menjadi data latih, validasi, dan uji.

### Pengembangan Model

Model klasifikasi dibangun menggunakan metode *transfer learning* dengan arsitektur CNN pra-latih. Lapisan akhir model diganti dengan *fully connected*

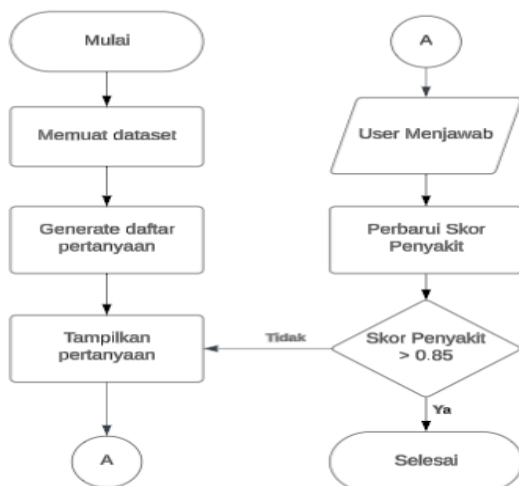
layer sesuai jumlah kelas apel. Parameter pelatihan meliputi *learning rate*, *batch size*, dan jumlah *epoch* yang ditentukan melalui eksperimen. Proses pelatihan dilakukan hingga konvergensi berdasarkan nilai *validation loss*.

### Evaluasi Model

Kinerja model dievaluasi menggunakan metrik klasifikasi berupa *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu digunakan *confusion matrix* untuk menganalisis kesalahan prediksi antar kelas. Model terbaik dipilih berdasarkan performa validasi dan stabilitas pelatihan.

### Implementasi Sistem

Model terpilih diintegrasikan ke dalam aplikasi berbasis web melalui layanan *cloud inference*. Pengguna mengunggah citra apel melalui antarmuka web, kemudian server memproses prediksi dan mengembalikan hasil klasifikasi secara *real-time*. Performa sistem diukur berdasarkan waktu respons dan konsistensi hasil prediksi.



Gambar 1. Flowchart Sistem

### Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa citra enam varietas apel, yaitu Braeburn, Crimson Snow, Golden, Granny Smith, Pink Lady, dan Red Delicious. Dataset diperoleh dari sumber dataset publik dan dikurasi untuk memastikan kualitas gambar sesuai kebutuhan klasifikasi. Setiap citra kemudian diberi label sesuai kelas varietasnya. Sebelum digunakan pada proses pelatihan, citra melalui tahap praproses meliputi *resizing*, normalisasi, dan augmentasi data berupa rotasi, flipping, dan perubahan pencahayaan untuk meningkatkan variasi data dan kemampuan generalisasi model. Dataset dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji untuk menghindari *overfitting* dan memastikan evaluasi model yang objektif.

### Analisis Data

Analisis dilakukan melalui dua tahap utama, yaitu analisis performa model dan analisis sistem.

#### 1. Analisis Performa Model

Model dievaluasi menggunakan metrik klasifikasi meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu digunakan *confusion matrix* untuk mengidentifikasi kesalahan prediksi antar kelas apel yang memiliki kemiripan visual.

#### 2. Analisis Sistem

Model terbaik diintegrasikan ke dalam aplikasi web melalui layanan *cloud inference*. Evaluasi sistem dilakukan dengan mengukur waktu respons prediksi serta konsistensi hasil klasifikasi terhadap berbagai kondisi citra.

Hasil analisis digunakan untuk menilai kemampuan model dalam mengenali perbedaan karakteristik visual antar varietas

apel serta kelayakan implementasi sistem pada penggunaan nyata.

## HASIL DAN PEMBAHASAN

### Antarmuka Aplikasi


Aplikasi dikembangkan berbasis web untuk klasifikasi jenis apel melalui unggahan citra, di mana sistem menampilkan hasil prediksi beserta tingkat keyakinan model secara otomatis. Desain antarmuka dibuat sederhana guna menjamin aksesibilitas bagi pengguna tanpa latar belakang teknis pembelajaran mesin. Implementasi ini sejalan dengan pandangan Koirala et al. (2019) bahwa integrasi model ke platform yang mudah diakses sangat krusial untuk menjembatani kesenjangan teknologi di sektor pertanian melalui sistem identifikasi yang praktis.

### Hasil Pelatihan Model

Model dilatih menggunakan arsitektur ResNet-50 dengan *optimizer* Adam (Kingma & Ba, 2015). Dataset enam varietas apel dibagi dengan rasio 85% data pelatihan dan 15% validasi selama 30 *epoch*. Nilai *training loss* menunjukkan penurunan konsisten, menandakan keberhasilan model dalam mengekstraksi fitur visual esensial seperti warna dan tekstur. Stabilitas kurva pelatihan mengindikasikan proses optimisasi parameter berjalan efektif tanpa gangguan teknis.

*Validation loss* turut menurun secara berkelanjutan tanpa kenaikan signifikan di akhir *epoch*, sehingga dapat disimpulkan tidak terdapat gejala *overfitting* (Prechelt, 2012). Kedekatan pola antara *loss* pelatihan dan validasi membuktikan kemampuan generalisasi model terhadap data baru yang belum pernah dilatih sebelumnya. Hasil ini

menegaskan bahwa penerapan *transfer learning* pada ResNet-50 sangat efektif untuk klasifikasi hortikultura karena mampu mengekstraksi fitur relevan sekaligus menjaga stabilitas pembelajaran (He et al., 2016; Shorten & Khoshgoftaar, 2019).



Gambar 2. Training Loss dan Validation Loss

Pada proses pelatihan model klasifikasi citra apel berbasis arsitektur ResNet-50, grafik *Training Loss* dan *Validation Loss* menjadi indikator utama untuk mengamati sejauh mana model memahami pola visual dari data serta kemampuannya dalam melakukan generalisasi. Grafik yang dihasilkan memperlihatkan garis *Training Loss* yang menurun signifikan dari 0,94 pada *epoch* pertama hingga mencapai 0,10 pada *epoch* ke-30. Penurunan konsisten tanpa lonjakan berarti ini menunjukkan bahwa model berhasil mengenali pola visual seperti warna kulit apel, karakteristik permukaan, kontras, pencahayaan, serta tekstur secara stabil (He et al., 2016).

Sementara itu, garis *Validation Loss* juga memperlihatkan pola penurunan yang berkelanjutan dari 1,10 hingga mencapai 0,36 pada *epoch* akhir. Tren yang stabil ini menunjukkan model tidak hanya menghafal data pelatihan, tetapi mampu memahami pola visual pada data validasi yang menandakan kemampuan generalisasi yang

baik (Goodfellow et al., 2016). Dari pola tersebut, dapat disimpulkan tidak terjadi *overfitting* karena *validation loss* tidak meningkat pada *epoch* akhir dan kecenderungan kedua garis bergerak sejajar (Prechelt, 2012). Selisih nilai (*gap*) antara *training loss* (0,10) dan *validation loss* (0,36) yang kecil mengindikasikan distribusi dataset seimbang serta tahap *preprocessing* yang memadai dalam mendukung ekstraksi ciri visual seperti saturasi warna dan kontur objek (Shorten & Khoshgoftaar, 2019).

### Hasil Evaluasi Model

Hasil evaluasi model disajikan dalam Tabel 2 yang memuat metrik *precision*, *recall*, *F1-score*, dan *support*. Keempat metrik ini memberikan gambaran menyeluruh mengenai kemampuan model dalam mengenali karakteristik setiap kelas secara akurat. Evaluasi dilakukan menggunakan *testing dataset* untuk memastikan bahwa hasil yang diperoleh benar-benar menggambarkan kemampuan generalisasi model terhadap data baru (Hameed et al., 2020). Konsistensi performa pada seluruh kelas menunjukkan bahwa ResNet-50 efektif dalam mengekstraksi fitur visual esensial untuk membedakan varietas apel secara konsisten (Siddiqi, 2019).

Tabel 1. Hasil Evaluasi per Kelas

Class	Precision	Recall	F1-Score	Support
Braeburn	0.94	0.93	0.94	180
Crimson Snow	0.92	0.90	0.91	160
Golden	0.95	0.96	0.96	200

Granny Smith	0.93	0.94	0.94	190
Pink Lady	0.96	0.95	0.96	175
Red Delicious	0.91	0.89	0.90	165


### Kinerja Model

Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik pada semua kelas apel. Seluruh kelas memiliki nilai F1-score di atas 0,90, yang menandakan bahwa model mampu mempertahankan keseimbangan antara *precision* (ketepatan prediksi) dan *recall* (cakupan prediksi). Nilai-nilai ini mencerminkan kualitas representasi fitur visual yang dipelajari model, terutama terkait tekstur, warna, dan pola permukaan buah (Hameed et al., 2020). Secara khusus, kelas Golden dan Pink Lady memiliki performa paling tinggi, masing-masing dengan F1-score mencapai 0,96. Hal ini menunjukkan bahwa model dapat mengenali kedua jenis apel tersebut dengan sangat baik, karena fitur visualnya yang lebih distingtif, seperti warna kulit yang konsisten dan pola permukaan yang khas.

Di sisi lain, kelas Red Delicious memiliki skor F1 terendah dibandingkan kelas lain, meskipun tetap berada pada

kisaran yang sangat baik, yaitu 0,90. Penurunan performa pada kelas ini dipicu oleh adanya kemiripan visual (*visual similarity*) yang cukup tinggi dengan kelas Crimson Snow, terutama pada aspek intensitas warna merah pekat dan tingkat kecerahan permukaan buah. Tumpang tindih fitur ini menimbulkan ambiguitas visual yang memaksa model memerlukan kecermatan ekstra dalam proses klasifikasi (Siddiqi, 2019). Secara keseluruhan, nilai metrik yang tinggi menunjukkan bahwa *preprocessing* data, augmentasi citra, serta struktur arsitektur ResNet-50 yang digunakan sudah tepat dalam menangani variasi bentuk, warna, cahaya, dan orientasi (Shorten & Khoshgoftaar, 2019).

Gambar 3 menampilkan grafik F1-Score untuk masing-masing kelas apel yang memberikan gambaran visual mengenai tingkat akurasi dan konsistensi performa model. Penggunaan metrik F1-Score pada grafik ini merepresentasikan keseimbangan antara kemampuan model dalam mengidentifikasi kelas dengan tepat (*precision*) dan kemampuannya dalam menangkap seluruh sampel yang benar (*recall*) secara komprehensif (Hussain et al., 2020). Dengan performa ini, model dianggap sangat layak diterapkan dalam aplikasi berbasis web untuk klasifikasi apel secara otomatis.



Gambar 3. F1-score

Secara umum, grafik menunjukkan bahwa model memiliki performa yang stabil dan merata di seluruh kelas, dengan nilai F1-Score yang berada pada rentang 0,90 hingga 0,96. Rentang nilai ini mengindikasikan bahwa model tidak hanya bekerja dengan baik pada kelas tertentu, tetapi juga konsisten dalam melakukan klasifikasi pada seluruh kategori apel yang diuji. Kestabilan performa ini menandakan bahwa proses pelatihan, arsitektur model, serta distribusi dataset telah berjalan dan disiapkan dengan baik (Hameed et al., 2020).

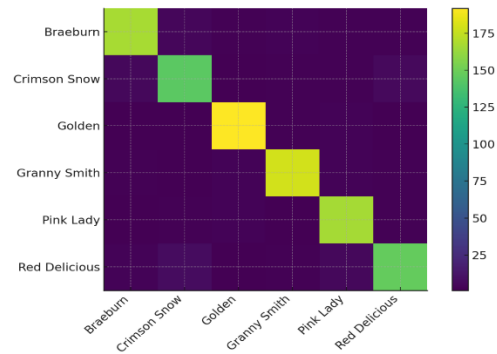
Dari grafik tersebut terlihat bahwa kelas Pink Lady dan Golden menempati posisi tertinggi dalam nilai F1-Score, yaitu sekitar 0,96. Hal ini dapat dimaknai bahwa kedua jenis apel ini memiliki ciri visual yang lebih mudah dikenali oleh model, baik dari segi warna, pola permukaan, maupun karakteristik tekstural lainnya. Kemudahan dalam diferensiasi ini memungkinkan model menghasilkan prediksi yang sangat akurat

dan konsisten pada kedua kelas tersebut (Siddiqi, 2019).

Sebaliknya, kelas Red Delicious menunjukkan nilai F1-Score paling rendah di antara seluruh kategori, meskipun tetap berada pada tingkat yang tinggi, yakni sekitar 0,90. Nilai yang sedikit lebih rendah ini dapat dikaitkan dengan adanya kemiripan fitur visual (*visual similarity*) antara Red Delicious dan Crimson Snow, khususnya dari sisi warna merah dominan dan keseragaman tekstur. Meski demikian, performa pada kelas ini tetap sangat baik dan masih memenuhi standar keandalan untuk implementasi dalam aplikasi klasifikasi berbasis web. Secara keseluruhan, grafik F1-Score ini menegaskan bahwa model memiliki kinerja yang kuat dan seimbang tanpa adanya penurunan performa ekstrem (Siddiqi, 2019).

*Confusion matrix* digunakan untuk melihat detail performa model dalam membedakan setiap kelas apel secara lebih spesifik. Tidak hanya menampilkan akurasi secara keseluruhan, *confusion matrix* menunjukkan jumlah sampel yang berhasil diklasifikasi dengan benar serta distribusi kesalahan klasifikasi ke kelas lain. Melalui analisis ini, dapat diidentifikasi pola kesalahan yang terjadi dan karakteristik visual mana yang menjadi sumber

ambiguitas antar kelas (Hussain et al., 2020).



Gambar 4. Confusion Matrix

Berdasarkan *confusion matrix* yang dihasilkan, sebagian besar sampel pada setiap kelas berhasil diprediksi dengan benar oleh model. Hal ini terlihat dari dominasi nilai diagonal pada matriks, yang menggambarkan prediksi benar untuk masing-masing kelas. Persentase klasifikasi benar untuk setiap kelas berada pada kisaran tinggi, sejalan dengan nilai *F1-Score* yang telah dibahas sebelumnya.

Namun matriks ini juga menunjukkan terdapat beberapa kesalahan klasifikasi, terutama antara kelas Red Delicious dan Crimson Snow. Kesalahan ini dapat dipahami karena kedua varietas tersebut memiliki kemiripan warna merah pekat pada kulit buahnya. Perbedaan visual yang cukup tipis menyebabkan model terkadang mengalami kesulitan dalam membedakan tekstur halus dan gradasi warna pada citra

tertentu (Hussain et al., 2020). Pola *misclassification* ini tidak dominan, namun memberikan wawasan berharga mengenai ambiguitas fitur visual dalam dataset (Siddiqi, 2019).

Kelas Golden dan Pink Lady menunjukkan tingkat kesalahan prediksi paling rendah. Ciri visual yang unik seperti warna kuning keemasan pada Golden dan warna merah muda cerah pada Pink Lady membantu model dalam melakukan diskriminasi secara konsisten. Secara keseluruhan, *confusion matrix* memperkuat kesimpulan bahwa model memiliki kemampuan diskriminatif yang kuat dan pola kesalahan yang terjadi bersifat logis secara visual (Hameed et al., 2020).

#### Pengujian Sistem Web PHP dan API Hugging Face

Pengujian dilakukan untuk mengevaluasi efektivitas integrasi aplikasi web berbasis PHP dengan API Hugging Face sebagai mesin inferensi. Fokus evaluasi meliputi mekanisme unggah citra, latensi pengiriman data, serta konsistensi prediksi untuk memastikan sinkronisasi antara *frontend*, *backend*, dan API berjalan secara responsif (Amani et al., 2021).

Alur sistem dimulai dari unggahan gambar oleh pengguna yang diteruskan melalui metode POST ke *endpoint* Hugging

Face, dengan luaran prediksi berupa format JSON. Pengujian pada enam varietas apel (Braeburn, Crimson Snow, Golden, Granny Smith, Pink Lady, dan Red Delicious) dilakukan untuk mengukur stabilitas waktu respons API. Implementasi *cloud inference* ini terbukti efektif dalam menjaga aplikasi tetap ringan di sisi klien tanpa mengurangi performa model *deep learning* yang kompleks (Wolf et al., 2020).

Tabel 2. Waktu Respon API

Jenis Apel	Waktu Respon API (detik)
Braeburn	0.82
Crimson Snow	0.85
Golden	0.78
Granny Smith	0.79
Pink Lady	0.81
Red Delicious	0.83

#### Analisis Latensi dan Keandalan Sistem

Hasil pengujian menunjukkan bahwa integrasi antara aplikasi web berbasis PHP dengan API Hugging Face berjalan stabil dan efisien. Seluruh permintaan inferensi diproses dengan waktu respons di bawah 1 detik, yang merupakan capaian optimal bagi aplikasi berbasis *machine learning* untuk pemrosesan citra (Li et al., 2018). Data

pengujian menunjukkan kelas Golden memiliki waktu respons tercepat (0,78 detik), diikuti oleh Granny Smith (0,79 detik). Sebaliknya, Crimson Snow mencatatkan waktu respons tertinggi sebesar 0,85 detik. Variasi ini diduga dipengaruhi oleh kompleksitas fitur visual atau ukuran file gambar uji, namun selisihnya tidak memberikan dampak signifikan terhadap pengalaman pengguna. Rata-rata waktu respons sebesar 0,81 detik mengindikasikan sistem mampu beroperasi secara hampir *real-time* dengan *delay* minimal (Srivastava & Bhambhu, 2021).

Dari aspek keandalan, seluruh percobaan berhasil diproses tanpa kegagalan sistem. Hal ini membuktikan bahwa protokol komunikasi HTTP, pengiriman data biner, serta *parsing* respons JSON berfungsi secara akurat. Stabilitas yang konsisten pada permintaan berturut-turut menegaskan bahwa pemanfaatan *cloud inference* sangat layak diimplementasikan pada aplikasi klasifikasi objek visual untuk skala kecil maupun menengah (Srivastava & Bhambhu, 2021).

## KESIMPULAN

Model klasifikasi citra apel berbasis *transfer learning* dengan arsitektur ResNet-50 mampu mengenali enam varietas apel secara konsisten dengan performa tinggi. Pola kesalahan yang muncul terutama disebabkan oleh kemiripan karakteristik

visual antar kelas, sehingga menunjukkan keterbatasan berasal dari sifat objek, bukan dari ketidakstabilan model.

Implementasi model melalui layanan inferensi berbasis web memungkinkan proses klasifikasi berlangsung cepat dan stabil tanpa memerlukan komputasi lokal. Hal ini menunjukkan bahwa integrasi *deep learning* dan *cloud inference* tidak hanya efektif secara akurasi, tetapi juga praktis untuk penggunaan nyata. Dengan demikian, pendekatan ini berpotensi diterapkan sebagai solusi otomasi identifikasi komoditas hortikultura yang akurat, efisien, dan mudah diakses.

## UCAPAN TERIMAKASIH

Penulis menyampaikan terima kasih kepada Program Studi Sistem Informasi Sekolah Tinggi Teknologi Bina Tunggal Bekasi atas dukungan fasilitas penelitian. Apresiasi juga diberikan kepada penyedia *dataset* terbuka pada platform Kaggle serta layanan *Hugging Face* yang telah memfasilitasi kebutuhan komputasi dan *deployment* model Deep Learning dalam penelitian ini. Terima kasih kepada dosen pembimbing dan seluruh pihak yang telah memberikan kontribusi teknis sehingga penelitian mengenai klasifikasi varietas apel ini dapat diselesaikan dengan baik.

## DAFTAR PUSTAKA

- Amani, J., Laryea, E. T., & Adjei, O. (2021). Integration of Machine Learning Models into Web Applications Using API Endpoints. *Journal of Software Engineering and Applications*, 14(8), 384-395.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M.,

- Heigold, G., Gelly, S., Uszkoreit, J., & Hounsby, N. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *International Conference on Learning Representations (ICLR)*.
- Giarratano, J. C., & Riley, G. D. (2005). *Expert Systems: Principles and Programming*. Course Technology.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hameed, K., Chai, D., & Rassau, A. (2020). A Comprehensive Review of Fruit and Vegetable Classification Techniques Using Computer Vision. *IEEE Access*, 8, 131295-131314.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Hussain, M., Bird, J. J., & Faria, D. R. (2020). A Study on CNN Transfer Learning for Image Classification. *UK Workshop on Computational Intelligence*, 191-202.
- Kingma, D. P., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations (ICLR)*.
- Koirala, A., Walsh, K. B., Wang, Z., & McCarthy, C. (2019). Deep learning for real-time fruit detection and orchard yield estimation: A review. *Computers and Electronics in Agriculture*, 162, 407–434.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436–444.
- Li, C., Hu, X., & Zhang, L. (2018). Performance Evaluation of Cloud-Based Machine Learning API Services. *IEEE International Conference on Cloud Computing*, 115-122.
- Luger, G. F. (2005). *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Pearson Education.
- Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.
- Prechelt, L. (2012). Early Stopping — But When?. In: Montavon, G., Orr, G. B., Müller, K. R. (eds) *Neural Networks: Tricks of the Trade*. Lecture Notes in Computer Science, vol 7700. Springer.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1-48.
- Siddiqi, R. (2019). Fruit Classification Using Deep Learning. *Software Engineering*, 7(4), 77-83.
- Silva, L. C., & Patel, P. (2021). Simple Vision System for Apple Varieties Classification. *Industria: Jurnal Teknologi dan Manajemen Agroindustri*, 10(3), 221–232.
- Srivastava, S., & Bhambhu, L. (2021). Web-based Image Classification Using Convolutional Neural Networks and Cloud Inference. *Journal of Physics: Conference Series*, 1963(1), 012143.
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., Cistac, P., Rault, T., Louf, R., Funtowicz, M., Davison, J., Shleifer, S., von Platen, P., Ma, C., Jernite, Y., Plu, J., Xu, C., Le Scao, T., Gugger, S., ... Rush, A. M. (2020). Transformers: State-of-the-Art Natural Language Processing. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, 38–45.

