

Optimalisasi Deteksi Tingkat Kematangan Buah Apel Menggunakan Arsitektur SSD-ResNet50

Muhamad Fajar Sayuto¹, Edga Sukma Pratama², Tomi Setiawan³

^{1,2,3}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹muhamadfajarsayuto@gmail.com, ²edgapratama@gmail.com, ³tomas.ignite123@gmail.com

Abstrak – Kualitas apel menjadi faktor penting dalam menjaga nilai jual dan keamanan konsumsi, sehingga diperlukan metode penilaian otomatis yang lebih akurat dibandingkan pemeriksaan manual yang bersifat subjektif. Studi ini mengembangkan sistem deteksi kualitas apel berbasis Computer Vision dengan menggunakan metode Single Shot Detector (SSD) dengan backbone ResNet50 sebagai model utama. Dataset terdiri dari citra apel segar dan busuk dengan melalui bagian resize, normalisasi, anotasi, dan augmentasi untuk meningkatkan variasi data. Model SSD-ResNet50 dilatih untuk mengklasifikasikan dua kategori kualitas apel dan dievaluasi menggunakan data uji terpisah. Hasil penelitian menunjukkan performa yang baik dengan akurasi 92%, precision 93% untuk kelas segar dan 91% untuk kelas busuk, serta recall masing-masing 87% dan 95%. Confusion matrix mengonfirmasi bahwa sebagian besar citra diuji berhasil diklasifikasikan dengan benar sehingga model dinilai stabil dan mampu mengekstraksi fitur citra secara efektif. Sistem ini kemudian diimplementasikan dalam aplikasi berbasis web untuk memudahkan proses deteksi kualitas apel secara praktis melalui unggahan gambar. Studi ini membuktikan bahwa pendekatan SSD-ResNet50 efektif dalam pengolahan citra untuk menilai kualitas apel dan berpotensi diterapkan dalam otomatisasi pengecekan mutu buah.

Kata Kunci — Apel, Computer Vision, Pengolahan Citra, Single Shot Detector, ResNet50

1. PENDAHULUAN

Apel merupakan Salah satu produk hortikultura dengan nilai pasar tinggi dan permintaan yang stabil. Kualitas kematangan apel ditentukan oleh sejumlah faktor, termasuk rasa, tekstur, warna, umur simpan, dan nilai jual buah. Penurunan kualitas dan kerusakan selama distribusi dapat terjadi akibat kesulitan dalam menentukan tingkat kematangan panen. Karena penilaian kematangan manual berdasarkan penilaian visual petani bersifat subjektif dan tidak konsisten, sangat penting untuk menggunakan teknologi otomatis yang dapat memberikan penilaian kematangan yang objektif, akurat, dan stabil [1].

Sistem deteksi dan klasifikasi buah otomatis kini memiliki lebih banyak opsi berkat perkembangan dalam teknologi *deep learning* dan penglihatan komputer. Studi terbaru menunjukkan bahwa teknik berbasis *Convolutional Neural Network (CNN)* secara signifikan meningkatkan akurasi dalam mengidentifikasi karakteristik fisik seperti kematangan, warna, dan tekstur [2]. Selain itu, kemampuan inferensi *real-time* dari model deteksi objek modern, seperti SSD (*Single Shot Multibox Detector*), sangat relevan untuk aplikasi di lapangan [3].

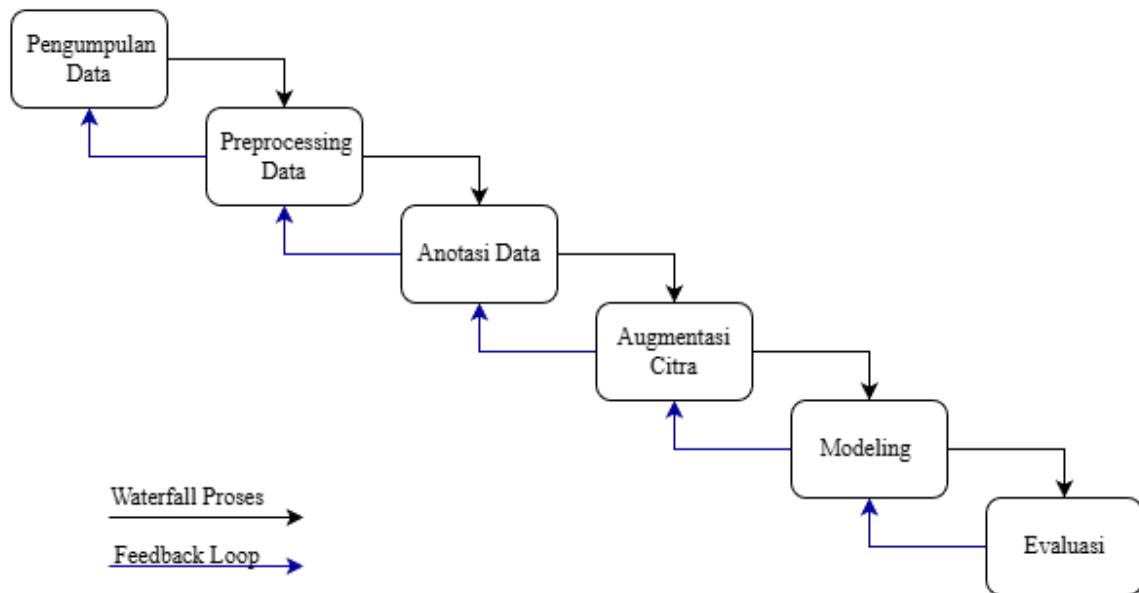
Arsitektur SSD-ResNet50 merupakan gabungan antara *ResNet50* sebuah ekstraktor fitur yang kuat melalui pembelajaran residual, dengan SSD sebuah detektor satu tahap. Telah dibuktikan bahwa *ResNet50* menghasilkan representasi mendalam yang stabil dalam berbagai kondisi pencahayaan dan visual [4]. Sistem ini dapat mengklasifikasikan kematangan apel dalam proses tunggal yang efektif berkat integrasi kedua arsitektur tersebut. Model ini sering digunakan untuk sistem berbasis web atau aplikasi portabel karena efisiensi komputasinya [5].

Studi terbaru telah menunjukkan keefektifan model SSD dan *ResNet50* dalam menentukan tingkat kematangan berbagai jenis buah. Teknik *deep learning* dapat mencapai akurasi tinggi dan nilai *mAP* dalam klasifikasi kematangan buah, berdasarkan penelitian pada apel, stroberi, dan tomat [6]. Namun, diperlukan penelitian lebih lanjut untuk mengevaluasi kinerja model secara menyeluruh, karena belum banyak penelitian yang secara khusus mengintegrasikan SSD dengan backbone *ResNet50* untuk mengklasifikasikan tingkat kematangan apel.

Oleh karena itu, tujuan penelitian ini adalah untuk mengembangkan sistem deteksi dan klasifikasi kematangan apel berdasarkan *SSD-ResNet50*. Data set kematangan apel dibuat, model *SSD-ResNet50* dilatih, kinerja dievaluasi menggunakan metrik *mAP* dan *F1-score*, dan sistem deteksi diuji dalam kondisi dunia nyata. Tujuan penelitian ini adalah untuk mengembangkan sistem yang akan membantu dalam panen dan pengklasifikasian apel secara lebih objektif, akurat, dan efektif.

2. METODE PENELITIAN

Penelitian ini menggunakan metodologi yang komprehensif untuk mengidentifikasi dan mengklasifikasikan tingkat kematangan apel. Pengumpulan data, *preprocessing*, dan implementasi model merupakan langkah-langkah yang terlibat. Pengumpulan data, pengelolaan data, *augmentasi* gambar, dan implementasi model hanyalah beberapa dari tahap utama proses ini. Gambar 1 menggambarkan alur penelitian sebagai berikut:



Gambar 1. *Waterfall Model*

2.1 Pengumpulan Data

Pengumpulan data pada penelitian menggunakan *roboflow*, terdapat 47 citra gambar buah apel dalam kategori *fresh* dan 65 citra gambar buah apel dengan kategori busuk.

2.2 Preprocessing Data

Tahap *preprocessing* dilakukan menggunakan beberapa cara, seperti mengubah ukuran gambar menjadi 448 x 448 piksel untuk memastikan setiap gambar memiliki ukuran yang konsisten dan memenuhi persyaratan arsitektur SSD-ResNet50 [7], serta menormalisasi piksel gambar agar model lebih mudah mempelajari pola visual. Setelah itu, setiap gambar apel dikonversi ke format RGB dan disimpan dalam struktur direktori dengan dua kategori yaitu apel busuk dan apel segar. Prosedur ini memastikan bahwa data yang masuk ke tahap anotasi dan pelatihan memiliki format yang konsisten dan stabil, sehingga dapat digunakan dalam *pipeline* deteksi SSD-ResNet50.

2.3 Anotasi Data

Untuk membedakan objek utama dari latar belakang dan memberikan detail tentang lokasi objek yang akan dianalisis oleh model, objek-objek ditandai pada gambar apel digital selama fase anotasi. Tahap ini sangat penting untuk membantu model SSD-ResNet50 dalam menganalisis fitur visual apel, khususnya perbedaan antara apel segar dan busuk berdasarkan luas permukaan buah, tekstur, dan pola warna [8].

Roboflow digunakan dalam proses analisis, yang memudahkan pengumpulan data set, analisis gambar, dan pembuatan kotak batas untuk setiap objek apel dalam gambar. Proses anotasi dilakukan menggunakan *Roboflow* untuk menggambar kotak batas di sekitar apel dan memberi label kelas berdasarkan kategori kematangan. Studi ini tidak menggunakan segmentasi penuh, tetapi segmentasi objek menggunakan fungsi identifikasi kotak batas merupakan bentuk segmentasi spasial yang membantu model fokus pada objek utama dan menghilangkan latar belakang yang tidak penting.

Selain itu, *Roboflow* menyediakan sejumlah fitur tambahan yang dapat digunakan pada fase lanjutan, termasuk bantuan anotasi otomatis, penyesuaian ukuran gambar, dan integrasi proses *augmentasi*. Model SSD-ResNet50 dapat meningkatkan akurasi deteksi dan klasifikasi dengan mempelajari posisi objek, batas, dan karakteristik kedua kelas yang dianalisis secara lebih efektif melalui analisis yang konsisten dan akurat [9]. Setiap

tabel dan grafik memerlukan nama dan nomor grafik. Setiap tabel dan grafik harus diberi nama sesuai dengan deskripsi atau penjelasannya.


2.4 Augmentasi Citra

Pada fase *augmentasi*, berbagai transformasi citra apel dilakukan untuk meningkatkan variabilitas data dan mengurangi risiko *overfitting* pada model *SSD-ResNet50*. Proses ini menggunakan beberapa teknik, seperti rotasi, pembalikan horizontal, penyesuaian kecerahan-kontras, dan penambahan sedikit *noise*, untuk mensimulasikan kondisi pencahayaan yang berbeda dan lingkungan pengambilan gambar. Dengan *augmentasi* ini, model dapat mempelajari karakteristik apel dari berbagai sudut dan kondisi visual, sehingga meningkatkan kemampuannya untuk generalisasi saat menganalisis apel matang atau busuk [10].

Roboflow menyediakan opsi *augmentasi* otomatis dan pengaturan intensitas transformasi yang digunakan untuk seluruh proses *augmentasi*. Untuk menghindari perubahan makna kelas dalam data set, *Roboflow* memastikan bahwa setiap gambar yang dihasilkan mempertahankan bentuk dasar dan karakteristik penting dari apel. Selain meningkatkan jumlah data yang berguna, *augmentasi* terkontrol ini memberikan variasi visual yang cukup bagi model untuk meningkatkan kinerja deteksi dan klasifikasi.

2.5 Modelling

Tingkat kematangan apel diidentifikasi dan diklasifikasikan menggunakan arsitektur *SSD-ResNet50* sebagai model utama selama fase pemodelan. Arsitektur ini dipilih untuk aplikasi *real-time* karena *SSD (Single Shot MultiBox Detector)* dapat dengan cepat mengidentifikasi objek dalam satu proses inferensi. Komponen visual penting dari foto apel, seperti pergeseran warna, tekstur kulit, dan indikator kematangan, diekstraksi menggunakan *ResNet50*. Ketika digabungkan dengan mekanisme koneksi residual, kemampuan *ResNet50* untuk mempertahankan informasi fitur memungkinkan model mengidentifikasi objek apel dengan lebih akurat dan mencapai kinerja klasifikasi yang lebih baik [10].



Gambar 2 Arsitektur *ResNet-50*

(Sumber Gambar : <https://jurnal.plb.ac.id/index.php/tematik/index/2443/3640>)

Pada gambar 2 dapat dilihat bahwa arsitektur *ResNet-50* dipilih karena memiliki kelebihan dalam mengekstrak fitur visual secara mendalam melalui 50 lapisan jaringan, arsitektur ini juga mendukung struktur residual *blocks* yang dapat mengatasi masalah *vanishing gradient* dan memungkinkan informasi *propagasi* akan lebih efisien [11].

Sebuah data set apel matang dan busuk (dua kelas) yang telah melalui *preprocessing* dan *augmentasi* digunakan dalam prosedur pelatihan. Melalui eksperimen awal, parameter pelatihan seperti laju pembelajaran, ukuran *batch*, dan jumlah *epoch* dimodifikasi untuk mencapai akurasi optimal tanpa *overfitting*. Optimasi berbasis *loss function Backpropagation* dan *SSD*, yang mencakup *localization loss* dan *confidence loss*, digunakan selama pelatihan untuk mengajarkan model perbedaan visual antara kelas. *SSD-ResNet50* dapat secara andal dan efisien mengidentifikasi apel dan menentukan tingkat kematangannya berkat teknik ini.

2.6 Evaluasi

Kinerja model *SSD-ResNet50* dalam mengidentifikasi dan mengklasifikasikan kematangan apel menggunakan *Confusion Matrix*, termasuk Akurasi, Presisi, *Recall*, Skor F1, dan *mAP*, telah dievaluasi. Untuk memastikan bahwa pengujian dilakukan pada data yang belum pernah dilihat oleh model sebelumnya, data set dibagi menjadi data pelatihan, validasi, dan pengujian. Hasil evaluasi memberikan gambaran umum tentang kemampuan model dalam mengidentifikasi apel matang dan busuk, serta menunjukkan apakah diperlukan informasi tambahan atau perubahan parameter untuk meningkatkan kinerja sistem. Tabel 1 menampilkan contoh *confusion matrix* [12].

Table 1. *Confusion Matrix*


Class	Kelas Positif	Kelas Negatif
Positif	TP (True Positive)	TN (True Negative)
Negatif	FP (False Positive)	FN (False Negative)

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Langkah awal yang krusial dalam penelitian adalah pengumpulan data, terutama saat mengembangkan sistem berbasis kecerdasan buatan (*AI*). Gambar tomat menjadi sumber data utama untuk pelatihan dan pengujian model dalam studi ini. Untuk memastikan kualitas gambar terbaik, kamera yang terpasang pada sistem konveyor penyortiran tomat dengan pencahayaan yang stabil digunakan dalam proses pengambilan gambar. Platform *Roboflow*, sebuah alat berbasis web yang dirancang untuk membantu pengelolaan data set di bidang penglihatan komputer, kemudian digunakan untuk mempersiapkan dan mengelola semua data yang dikumpulkan, mulai dari pengunggahan data hingga pelatihan model.

Studi ini menggunakan total 112 gambar, 47 di antaranya adalah gambar tomat segar dan 65 di antaranya adalah gambar tomat busuk. Untuk mencegah ketidakseimbangan kelas, yang dapat mempengaruhi kinerja model, data dibagi secara merata antara kedua kategori. Fase penandaan, pelatihan, dan evaluasi sistem deteksi kematangan tomat semuanya menggunakan data yang dikumpulkan. Gambar 3 menunjukkan contoh hasil pengumpulan data.




Gambar 3 Hasil Pengumpulan Data

Gambar 3 menampilkan hasil dari prosedur pengumpulan data platform *Roboflow*. *Roboflow* menyediakan sejumlah fitur tambahan, termasuk *augmentasi* data dan anotasi, yang memudahkan pengguna untuk melakukan langkah-langkah *preprocessing* secara sistematis. Fitur-fitur ini memungkinkan pengguna untuk memberi label pada objek yang diteliti dengan lebih akurat dan menambah variasi pada data gambar.

Roboflow meningkatkan efisiensi proses persiapan data set sebelum digunakan dalam fase pelatihan model. Data set akhir berada dalam kondisi ideal, yang meningkatkan kinerja dan akurasi model dalam deteksi dan klasifikasi objek. Untuk memperlancar alur, saya juga dapat menggabungkan paragraf ini langsung dengan subbab pengumpulan data jika Anda menginginkannya.

3.2 *Preprocessing* Data


Karena jumlah data yang digunakan dalam penelitian ini relatif terbatas, maka dilakukan proses *preprocessing* untuk meningkatkan kualitas dan variasi data sebelum digunakan dalam pelatihan model. Salah satu tahapan awal *preprocessing* adalah *resize* seperti pada gambar 4, yaitu perubahan ukuran seluruh citra menjadi 224×224 piksel agar sesuai dengan ukuran *input* model yang digunakan. Meskipun ukuran asli citra berbeda-beda, proses *resize* ini bertujuan untuk menyeragamkan dimensi gambar sehingga pelatihan model dapat berlangsung secara stabil dan efektif. Selain itu, dilakukan pula proses normalisasi, yaitu penyesuaian nilai *piksel* dari rentang 0–255 menjadi 0–1, sehingga mempermudah model dalam memproses data dan mempercepat proses konvergensi selama pelatihan.



Gambar 4 *Resize dan Normalisasi*

3.3 Anotasi Data

Langkah penting dalam mempersiapkan data set untuk digunakan dalam pelatihan model kecerdasan buatan adalah anotasi data. Setiap gambar tomat dalam studi ini diberi label sesuai dengan tingkat kematangannya, yaitu tomat segar dan tomat busuk. Proses anotasi bertujuan untuk memberikan informasi kelas yang jelas kepada model agar dapat mempelajari perbedaan karakteristik visual setiap kategori. Platform *Roboflow*, yang menawarkan fitur penandaan objek yang sederhana dan terorganisir, digunakan sepanjang proses anotasi untuk memastikan setiap gambar memiliki informasi kelas yang relevan.




Gambar 5 Anotasi Data

Untuk membantu model dalam mengidentifikasi ciri visual utama tomat, objek-objek dipisahkan dari latar belakang selain diberi label. Tujuan langkah ini adalah untuk meminimalkan gangguan latar belakang dan menonjolkan area objek. Gambar 5 menunjukkan hasil anotasi data tomat segar dan busuk. Anotasi yang akurat dan konsisten membuat data set lebih representatif, yang meningkatkan kemampuan model untuk mengklasifikasikan kematangan tomat dengan akurat.

3.4 *Augmentasi* Citra

Untuk meningkatkan kemampuan model dalam mengidentifikasi kondisi objek yang berbeda, *augmentasi* gambar digunakan untuk meningkatkan jumlah dan variasi data pelatihan. Gambar tomat dalam studi ini di-*augmentasi* menggunakan teknik *flipping* atas-bawah dan *flipping* kiri-kanan. Tujuan metode ini adalah untuk menciptakan perubahan posisi objek tanpa mengubah atribut utama tomat. Dengan *augmentasi*, data set menjadi lebih bervariasi, memungkinkan model untuk mengidentifikasi tomat dalam berbagai orientasi daripada hanya bergantung pada sudut pandang tertentu. Prosedur ini sangat penting untuk meningkatkan kemampuan generalisasi model dan mengurangi kemungkinan *overfitting* selama pelatihan.



Gambar 6 Hasil Deteksi Citra

Gambar 6 menampilkan hasil deteksi kematangan tomat, dengan skor kepercayaan untuk setiap objek yang terdeteksi berkisar antara 0,2 hingga 1,0. Angka-angka ini menunjukkan seberapa yakin model dalam mengklasifikasikan tomat sebagai segar atau busuk. Rentang skor kepercayaan yang dihasilkan menunjukkan bahwa model mampu mengidentifikasi tingkat kematangan tomat dengan akurat. Karena hal ini secara langsung memengaruhi kualitas hasil penyortiran dan keandalan sistem dalam mendukung proses distribusi produk hortikultura.

3.5 Modelling


Classification report:				
	precision	recall	f1-score	support
segar	0.93	0.87	0.90	47
busuk	0.91	0.95	0.93	65
accuracy			0.92	112
macro avg	0.92	0.91	0.92	112
weighted avg	0.92	0.92	0.92	112

Gambar 7 Proses Modelling menggunakan ResNet50

Evaluasi kinerja dilakukan menggunakan laporan klasifikasi pada 112 data gambar uji, yang meliputi 47 gambar tomat segar dan 65 gambar tomat busuk, berdasarkan hasil pengujian model yang ditampilkan pada Gambar 7. Metrik evaluasi yang digunakan meliputi presisi, *recall*, *f1-score*, dan akurasi. Berdasarkan hasil pengujian, kelas tomat busuk memperoleh presisi 0,91, *recall* 0,95, dan *f1-score* 0,93, sementara kelas tomat segar memperoleh nilai presisi 0,93, *recall* 0,87, dan *f1-score* 0,90. Nilai akurasi keseluruhan model sebesar 92% menunjukkan bahwa sistem dapat mengklasifikasikan sebagian besar data uji dengan benar.

Nilai *macro average* dan *weighted average* yang masing-masing mencapai 0,92 pada seluruh metrik evaluasi menandakan bahwa performa model tergolong seimbang terhadap kedua kelas. Tingginya nilai *precision* menunjukkan bahwa kesalahan prediksi yang dilakukan model relatif kecil, sementara nilai *recall* yang tinggi menandakan bahwa model mampu mendeteksi sebagian besar tomat sesuai dengan kelas sebenarnya. Perbedaan nilai *recall* antara kelas segar dan busuk menunjukkan bahwa model cenderung lebih sensitif dalam mendeteksi tomat busuk, yang merupakan aspek penting dalam sistem pemilahan berbasis konveyor karena kesalahan dalam mendeteksi tomat busuk dapat berdampak langsung pada kualitas hasil sortir. Dengan hasil tersebut, dapat disimpulkan bahwa model klasifikasi yang dikembangkan telah bekerja dengan baik dan layak digunakan dalam sistem deteksi kematangan tomat secara otomatis.


3.6 Matriks Evaluasi



Gambar 8 *Confusion matrix*

Hasil evaluasi kinerja model untuk 112 data uji, yang dibagi menjadi dua kelas tomat segar dan tomat busuk ditampilkan dalam Gambar 8 sebagai *confusion matrix*. Menurut *confusion matrix*, 41 data tomat segar diklasifikasikan dengan benar sebagai segar, sementara 6 data tomat segar diklasifikasikan secara salah sebagai busuk. Tiga data tomat busuk diklasifikasikan secara salah sebagai segar, sementara 62 data dalam kelas tomat busuk diklasifikasikan dengan benar sebagai busuk. Nilai akurasi sebesar 92% diperoleh dari hasil keseluruhan ini, menunjukkan bahwa model dapat mengidentifikasi sebagian besar data uji dengan akurat.

Metrik evaluasi untuk kelas tomat segar adalah 93,2% presisi dan 87,2% *recall* berdasarkan nilai dalam *confusion matrix*, sedangkan kelas tomat busuk mendapatkan 91,2% presisi dan 95,4% *recall*. Karena kesalahan dalam mengidentifikasi tomat busuk dapat langsung memengaruhi kualitas hasil penyortiran, nilai-nilai ini menunjukkan bahwa model lebih sensitif dalam mengidentifikasi tomat busuk daripada tomat segar. Secara keseluruhan, model telah menunjukkan kinerja yang stabil dan dapat diandalkan dalam membedakan antara tomat segar dan tomat busuk berdasarkan gambar digital, meskipun masih ada beberapa kesalahan klasifikasi.



Gambar 9 Evaluasi Loss dan Akurasi

Grafik perkembangan kerugian total dan akurasi selama proses pelatihan model ditampilkan pada Gambar 9. Model berhasil mempelajari pola data dengan baik, seperti yang terlihat pada grafik *loss*, yang menunjukkan bahwa nilai kerugian pada data pelatihan menurun secara stabil dan bertahap dari *epoch* pertama hingga akhir. Di sisi lain, nilai kerugian pada data validasi tampak lebih fluktuatif, terutama pada *epoch* awal di mana terjadi lonjakan yang relatif besar. Secara keseluruhan, tren kerugian validasi terus menurun, dan pada *epoch* terakhir, nilainya mendekati kerugian data pelatihan, menunjukkan bahwa model masih mampu generalisasi dengan baik dan tidak mengalami *overfitting* yang signifikan.

Kemampuan model untuk mengidentifikasi pola gambar dalam data pelatihan ditunjukkan oleh grafik akurasi, yang menunjukkan bahwa akurasi pelatihan terus meningkat hingga mendekati 100% pada *epoch* terakhir.

Meskipun fluktuasinya lebih besar daripada data pelatihan, akurasi validasi juga menunjukkan tren peningkatan. Nilai akurasi validasi kembali meningkat pada *epoch* berikutnya dan stabil di sekitar 90% pada tahap akhir pelatihan, meskipun kadang-kadang terjadi penurunan akurasi yang signifikan. Polanya menunjukkan bahwa model berfungsi secara konsisten dan mendukung hasil evaluasi pada *confusion matrix*, yang menghasilkan akurasi keseluruhan 92%, meskipun terdapat variasi pada data validasi.

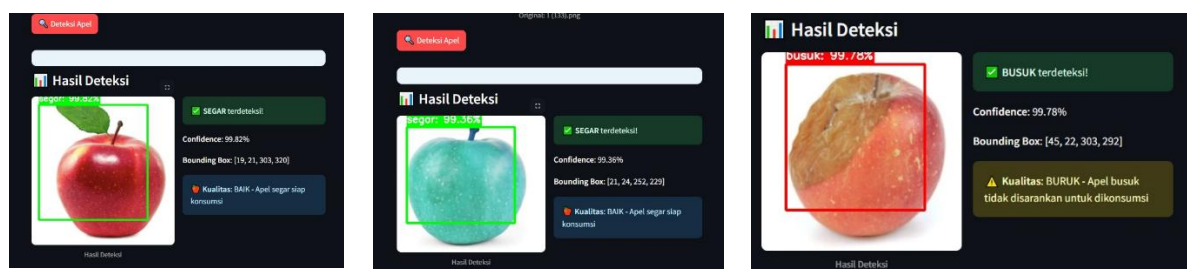
Secara keseluruhan, grafik pada Gambar 9, yang menunjukkan penurunan yang konsisten dalam tingkat kesalahan dan peningkatan yang signifikan dalam akurasi untuk kedua jenis data, menunjukkan proses pelatihan model yang berjalan dengan baik. Kemampuan model yang kuat untuk membedakan antara gambar tomat segar dan busuk ditunjukkan oleh tren keseluruhan, meskipun fluktuasi pada kurva validasi adalah hal yang umum mengingat variasi dalam data uji. Model mampu generalisasi dengan cukup baik pada data yang belum pernah dilihat sebelumnya dan dapat dianggap telah mencapai kinerja optimal.

3.7 Implementasi (*Stramlit*)



Gambar 10 Tampilan *Upload Gambar*

Fitur unggah gambar, yang memungkinkan pengguna mengunggah gambar apel menggunakan tombol “*Browse files*” atau seret dan lepas, ditampilkan pada Gambar 10. Setelah *file* dipilih, sistem akan menggunakan model *SSD-ResNet50* untuk memproses gambar dan menampilkan hasil deteksi secara *real-time*, memungkinkan pengguna untuk dengan cepat menilai kualitas apel melalui antarmuka yang intuitif.



Gambar 11 Hasil Deteksi Apel

Setelah model memproses gambar apel, Gambar 11 menampilkan hasil deteksi. Sistem mampu membedakan antara apel segar dan busuk dengan tingkat *confidence* lebih dari 95%. Panel informasi di sebelah kanan menampilkan detail prediksi, seperti status deteksi, nilai *confidence*, dan kualitas apel yang diklasifikasikan sebagai BAIK dan siap dikonsumsi atau BURUK dan tidak layak dikonsumsi, sementara *Bounding box* hijau menunjukkan lokasi apel pada gambar segar dan *Bounding box* merah menunjukkan apel busuk. Antarmuka ini memberikan *output* yang mudah dipahami, jelas, dan informatif bagi pengguna.

4. SIMPULAN

Dengan mempertimbangkan hasil penelitian dan evaluasi yang telah digunakan, adapun beberapa kesimpulan yang didapat sebagai berikut:

1. Perluasan dan variasi data set menjadi langkah penting untuk meningkatkan akurasi model. Data set sebaiknya ditambah dengan gambar apel dari berbagai varietas, kondisi kesegaran, latar belakang, dan pencahayaan yang beragam. Hal ini akan membantu model belajar lebih banyak pola visual dan membuat sistem lebih *robust* terhadap kondisi nyata di lapangan.
2. Pelatihan model dapat ditingkatkan dengan menambah jumlah *epoch*, menerapkan teknik data *augmentation* yang lebih bervariasi seperti *rotation*, *brightness adjustment*, *sharpening*, dan *background alteration* untuk mengurangi *overfitting*. Selain itu, eksperimen dengan *learning rate scheduling* dan *regularization* dapat membantu memperbaiki stabilitas pelatihan.
3. Pengujian model pada kondisi pencahayaan dan sudut pengambilan gambar yang berbeda dianjurkan agar performa model tetap konsisten pada situasi yang tidak ideal, misalnya pada proses sortir di gudang, minimarket, atau area distribusi yang memiliki pencahayaan bervariasi.
4. Integrasi teknik pemrosesan citra lanjutan seperti peningkatan resolusi gambar (*super-resolution*), segmentasi objek untuk memisahkan apel dari latar belakang, atau *noise reduction* dapat membantu meningkatkan ketepatan *bounding box* dan kejelasan fitur visual yang dianalisis model *SSD-ResNet50*.
5. Eksplorasi model lain dalam bidang deteksi dan klasifikasi citra juga layak dipertimbangkan. Arsitektur yang lebih mutakhir seperti *EfficientNet*, *YOLOv8*, *Faster R-CNN*, atau *backbone* lebih dalam seperti *ResNet101* dapat dibandingkan untuk mengetahui model mana yang memiliki tingkat ekstraksi fitur lebih tinggi, akurasi lebih baik, serta kecepatan inferensi lebih optimal pada platform web.
6. Pengembangan lebih lanjut pada aplikasi web dapat dilakukan dengan menambahkan fitur deteksi video *real-time*, penyimpanan riwayat deteksi, serta integrasi kamera eksternal untuk mendukung kebutuhan industri. Selain itu, penguatan *UX/UI* agar lebih responsif dan interaktif juga dapat meningkatkan kenyamanan pengguna.

5. SARAN

Untuk membuat model lebih adaptif dalam lingkungan dunia nyata, disarankan agar penelitian selanjutnya menambahkan variasi yang lebih banyak pada data set, terutama terkait kondisi pencahayaan dan latar belakang, guna meningkatkan kinerja deteksi kualitas apel. Untuk meningkatkan kemampuan generalisasi, dapat ditambahkan lebih banyak *epoch* dan *augmentasi* data yang lebih kaya pada proses pelatihan model. Kemudahan penggunaan dan kepraktisan aplikasi web juga akan ditingkatkan dengan penambahan fitur-fitur baru.

DAFTAR PUSTAKA

- [1] J. J. Sihombing, “Rancang Bangun Sistem Sortir dan Deteksi Berat Buah Sawit Berbasis Outseal PLC,” 2024.
- [2] I. Afandy, B. N. Ahmad, and M. R. Amartharizqi, “Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception,” *Jurnal Ilmiah Teknologi Informasi dan Robotika*, vol. 6, no. 2, pp. 88–98, 2024.
- [3] B. Baharuddin, Y. Yuyun, and N. Nasrullah, “Deteksi Kebakaran Menggunakan Algoritma Single Shoot MultiBox Detector dengan Rule RGB dan Rule YcbCr,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 1, pp. 391–404, Jan. 2025, doi: 10.57152/malcom.v5i1.1761.
- [4] E. Perdana, K. Ihsan, R. A. Pramudya, and R. E. Permana, “KLASIFIKASI CITRA ULOS BATAK MENGGUNAKAN METODE SVM DAN KNN DENGAN EKSTRAKSI FITUR BERBASIS RESNET50,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 5, pp. 8711–8718, 2025.
- [5] Z. K. Salsabila, “Analisis Arsitektur ResNet pada Single Shot Detector (SSD) untuk Deteksi Sampah,” 2025.

- [6] M. Masparudin, I. Fitri, and S. Sumijan, “Development of apple fruit classification system using convolutional neural network (cnn) mobilenet architecture on android platform,” *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 1, pp. 230–243, 2024.
- [7] F. NURSULISTIO, “Deteksi Objek Masker Menggunakan Object Detection API dan TensorFlow Lite Model Maker,” 2022.
- [8] N. F. Y. Putra, “EVALUASI PENGARUH VARIASI TINGKAT ANOTASI TERHADAP PERFORMA DAN EFISIENSI MODEL YOLOv11 PADA DETEKSI MULTI-OBJEK BUAH,” 2025.
- [9] A. N. Faturrohman, S. H. Suryawan, and A. Rahim, “Pengembangan Model Klasifikasi Kendaraan Keluar Masuk Area Parkir Dengan Algoritma YOLOv8,” *Teknika*, vol. 13, no. 3, pp. 370–379, 2024.
- [10] M. M. Nugraha, M. D. F. Saputra, D. A. Fauzan, and E. Y. Puspaningrum, “Augmentasi Data Pengenalan Citra Batik Yogyakarta Menggunakan Pendekatan Random Crop, Rotate, Dan Mixup,” in *Prosiding Seminar Nasional Informatika Bela Negara (SANTIKA)*, 2025, pp. 152–158.
- [11] A. Sihabillah, A. Tholib, and I. I. Basit, “OPTIMASI MODEL RESNET50 UNTUK KLASIFIKASI SAMPAH,” *Indexia*, vol. 6, no. 2, pp. 102–111, 2024.
- [12] M. FADLI and R. A. Saputra, “Klasifikasi dan evaluasi performa model Random Forest untuk prediksi stroke,” *Jurnal Teknik*, vol. 12, no. 2, 2023.