

IDENTIFIKASI TINGKAT KEMATANGAN DAN KUALITAS BUAH STROBERI MENGUNAKAN DEEP LEARNING

IDENTIFYING THE RIPENESS AND QUALITY LEVEL OF STRAWBERRIES USING DEEP LEARNING

Siti Azizah¹, Ledy Novamizanti², Sofia Sa'idah³

Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

¹sitiiazizahh@student.telkomuniversity.ac.id, ²ledyaldn@telkomuniversity.ac.id,
³sofiasaidahsfi@telkomuniversity.ac.id

Abstrak

Stroberi merupakan salah satu buah populer di Indonesia. Pada tahun 2022, BPS mencatat produksi stroberi mencapai 28,895 ton, meningkat 193,05% dari tahun sebelumnya. Jawa Barat menjadi penghasil utama dengan produksi 25,413 ton, mencapai 87,95% dari total produksi. Namun, proses penyortiran masih dilakukan secara konvensional untuk menentukan kematangan dan kualitas buah, sehingga memakan waktu dan sumber daya.

Sistem ini memanfaatkan teknologi *deep learning* dengan model YOLOv7 dan EfficientNetV2S, serta terintegrasi dengan *cloud* dan diimplementasikan pada aplikasi Android. Aplikasi ini mengirimkan gambar ke sistem *deep learning* yang akan memproses dan mengklasifikasikan kematangan stroberi, menampilkan tingkat kepercayaan dan hasil klasifikasi di *smartphone*.

Berdasarkan hasil pengujian, sistem dapat mengidentifikasi lima kategori: Matang *Grade-A*, Matang *Grade-B*, Setengah Matang *Grade-A*, Setengah Matang *Grade-B*, dan Tidak Matang. Nilai *loss* untuk *Box* dan *Val Box* masing-masing 0,02095 dan 0,03029; *Objectness* dan *Val Objectness* 0,004057 dan 0,00333; *Classification* dan *Val Classification* 0,008343 dan 0,007392. Evaluasi model klasifikasi menghasilkan *precision*, *recall*, dan *F1-Score* masing-masing 0,990 serta akurasi 99%. Waktu pemrosesan di *cloud* mencapai 1-2 detik dan klasifikasi 180 milidetik. *Usability testing* pada 33 responden menunjukkan skor dominan 4 dan 5, serta aplikasi dapat diinstal pada berbagai versi Android tanpa memakan banyak ruang memori atau mengalami crash.

Kata kunci : *deep learning, cloud, mobile application, matang, kualitas*

Abstract

Strawberries are one of the most popular fruits in Indonesia. In 2022, the Central Statistics Agency (BPS) recorded strawberry production at 28,895 tons, a 193.05% increase from the previous year. West Java was the main producer, with 25,413 tons, accounting for 87.95% of total production. However, the sorting process is still done conventionally to determine the ripeness and quality of the fruit, which consumes time and resources.

This system utilizes deep learning technology with YOLOv7 and EfficientNetV2S models, integrated with the cloud and implemented on an Android application. The app sends images to the deep learning system, which processes and classifies the ripeness of strawberries. The smartphone displays the confidence level and classification results.

Based on testing, the system can identify five categories: Ripe Grade-A, Ripe Grade-B, Half-Ripe Grade-A, Half-Ripe Grade-B, and Unripe. The loss values for Box and Val Box are 0,02095 and 0,03029, respectively; Objectness and Val Objectness are 0,004057 and 0,00333; Classification and Val Classification are 0,008343 and 0,007392. The classification model evaluation showed precision, recall, and F1-Score of 0.990 each and an accuracy of 99%. Cloud processing time reached 1-2 seconds with object classification at 180 milliseconds. Usability testing with 33 respondents showed dominant scores of 4 and 5, and the application can be installed on various Android versions without consuming much memory or crashing.

Keywords: *deep learning, cloud, mobile application, ripeness, quality*

1. Pendahuluan

Stroberi (*Fragaria x ananassa*) merupakan salah satu buah populer yang sering dikonsumsi dalam bentuk segar maupun olahan dan merupakan jenis buah-buahan yang memiliki ekonomi yang tinggi dan bermanfaat sehingga memiliki tingkat permintaan yang tinggi [1]. Badan Pusat Statistik (BPS) melaporkan, produksi stroberi di Indonesia mencapai 33.414 ton pada tahun 2022 [2]. Jumlah tersebut melonjak hingga 238,9% dibandingkan pada tahun sebelumnya yang sebesar 9.860 ton. Jawa Barat merupakan penghasil stroberi terbesar di Indonesia dengan produksi sebesar 25.413 ton pada 2022 [2]. Jumlah tersebut setara dengan 87,94% dari total produksi stroberi di Indonesia sepanjang tahun lalu. Melihat tren tersebut, seleksi tingkat kematangan pada buah stroberi merupakan upaya untuk meningkatkan kualitas buah stroberi. Tingkat kematangan dalam panen merupakan faktor penting yang menentukan kualitas buah, stroberi yang matang optimal akan memberikan rasa, dan nilai gizi yang optimal. Selain itu, stroberi sangat rentan terhadap kerusakan

di iklim subtropis dengan kelembaban tinggi, sehingga perlu ada keseimbangan antara tingkat kematangan dan kandungan nutrisi buah [3].


Untuk menjaga kualitas, memilih stroberi pada tingkat kematangan yang tepat adalah langkah penting. Namun, proses *sorting* masih dilakukan tradisional bisa jadi tidak efisien dan rentan terhadap kesalahan. Beberapa peneliti sebelumnya telah meneliti penilaian tingkat kematangan dan kualitas stroberi. Haili Zhou dkk. [4] melakukan penelitian tentang klasifikasi kematangan stroberi dengan menggabungkan teknik *Dark Channel Prior* dan metode YOLOv5 untuk meningkatkan akurasi pengenalan stroberi, terutama pada kondisi minim cahaya. Penelitian ini mengusulkan model pengenalan berbasis YOLOv5 untuk mendapatkan informasi yang akurat tentang buah dan kuncup bunga kiwi, sehingga memfasilitasi pengembangan strategi penyerbukan yang tepat. Pada penelitian ini, dilakukan perbandingan antara model YOLOv5m, YOLOv5l, dan YOLOv5x. Dari hasil perbandingan tersebut, YOLOv5s mengungguli model lainnya dengan akurasi prediksi sebesar 96,7% dan rasio nilai F1 sebesar 90,12. Kemudian Youchen Fan dkk. [5] mengusulkan model klasifikasi buah stroberi menggunakan YOLOv5, bertujuan untuk mengatasi masalah rendahnya akurasi dalam pemetikan buah stroberi dan tingginya tingkat kesalahan pemetikan atau kegagalan pemetikan. Penelitian tersebut menunjukkan akurasi pelatihan sebesar 85% dan akurasi pengujian sebesar 90%. Namun, metode ini membutuhkan peningkatan jumlah sampel dan pemilihan metode peningkatan citra yang berbeda dalam kondisi pencahayaan yang sama untuk meningkatkan efisiensi dan mencapai akurasi yang lebih tinggi.

D. Antony dan A. N. Fajar [6] mengusulkan sebuah metode menggunakan YOLOv7 sebagai model *convolutional neural network* (CNN) untuk mendeteksi kematangan pisang. Model YOLOv7 mendeteksi pisang berdasarkan warna kulitnya dan membedakan antara pisang *grade A* dan *grade B*. Penelitian ini bertujuan untuk meningkatkan metode penilaian kualitas buah dan menawarkan solusi potensial untuk meningkatkan kualitas buah yang dipanen. Penelitian ini memperoleh rata-rata *Average Precision* (mAP) sebesar 78,1% dan nilai *Average Precision* (AP) sebesar 99,5%. Berdasarkan penelitian-penelitian tersebut, penelitian ini akan mengusulkan sebuah aplikasi *non real time*. Penelitian ini bertujuan untuk meningkatkan efisiensi dan akurasi dalam menilai kematangan stroberi dan mengklasifikasikan kualitasnya melalui pengintegrasian *deep learning* ke dalam praktik pertanian. Penelitian ini akan menggunakan model *deep learning* YOLOv7-EfficientNetV2S, *cloud* dan *application mobile*.

2. Dasar Teori

2.1 Deep Learning

Deep learning pada penelitian ini memiliki peran dalam proses pengklasifikasian buah stroberi dengan menggunakan algoritma *Convolutional Neural Network* (CNN) [7]. Tujuannya adalah untuk menentukan tingkat kematangan dan kualitas buah stroberi dengan melatih model *deep learning* menggunakan dataset yang dikumpulkan langsung dari perkebunan. Proses *deep learning* dalam penelitian ini diilustrasikan dalam Gambar 1.



Gambar 1. Proses *deep learning*

Proses *deep learning* melibatkan dua jenis model, yaitu model deteksi objek dan model klasifikasi. Model deteksi objek digunakan untuk mengidentifikasi lokasi stroberi dalam gambar, sementara model klasifikasi bertanggung jawab untuk menentukan tingkat kematangan dan kualitasnya. Oleh karena itu, kombinasi dari kedua jenis algoritma ini memungkinkan sistem secara efektif mengklasifikasikan buah stroberi berdasarkan parameter yang ditetapkan.

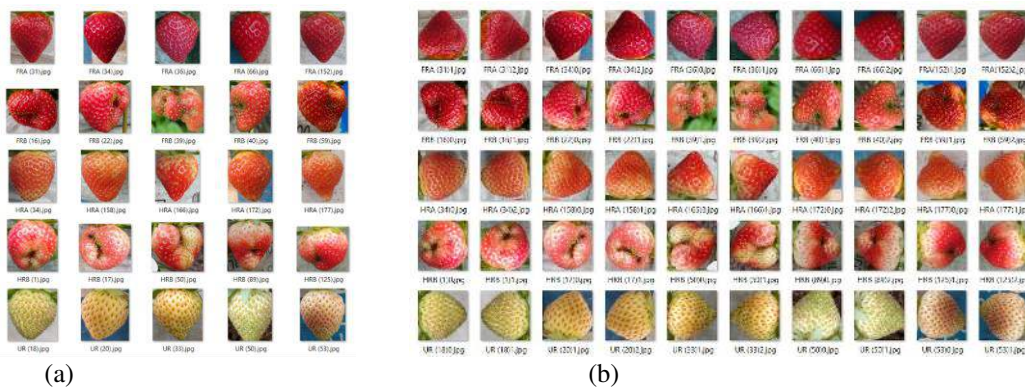
2.1.1 Model Deteksi Objek

Model deteksi objek yang digunakan dalam penelitian ini adalah YOLOv7 yang dikenal dengan arsitektur deteksi objeknya. YOLOv7 memiliki karakteristik utama dalam kecepatan deteksi yang tinggi, presisi yang baik, serta kemudahan dalam pelatihan dataset dan implementasinya. Pada penelitian ini, YOLOv7 digunakan khususnya untuk mendeteksi buah stroberi dan melakukan proses cropping terhadap bagian badan buah stroberi dari gambar input seperti pada Gambar 2.



Gambar 2. Proses pengolahan gambar menggunakan YOLOv7

Gambar 2. menampilkan proses pengolahan gambar menggunakan YOLOv7, hasil deteksi dan cropping tersebut kemudian diteruskan ke model klasifikasi. Proses ini dirancang untuk mempermudah proses pelatihan dan klasifikasi tingkat kematangan serta kualitas buah stroberi secara akurat menggunakan model klasifikasi. Beberapa sampel gambar yang telah melalui proses deteksi dan cropping menggunakan YOLOv7 ditunjukkan pada Gambar 3(a).



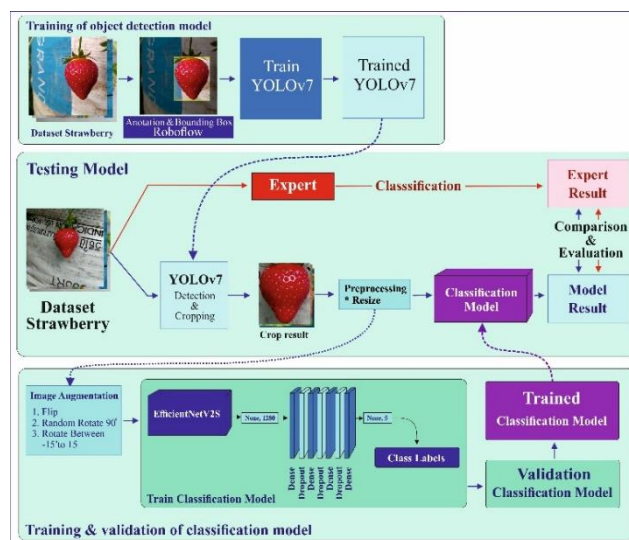
Gambar 3. Data sampel: (a). Data setelah *cropping* dan (b). Data setelah Augmentasi

Dataset yang telah melalui proses deteksi dan *cropping* akan mengalami proses augmentasi dengan menggunakan teknik *resize*, *flip*, dan rotasi. Teknik *resize* digunakan untuk menyamakan variasi gambar sesuai ketentuan inputan untuk model klasifikasi, untuk memastikan ukuran gambar konsisten dan sesuai dengan format yang diinginkan oleh model. Sementara itu, teknik *flip* dan rotasi berfungsi untuk membuat variasi gambar yang lebih banyak sehingga model dapat mendeteksi dan mengidentifikasi gambar stroberi dengan sudut pandang dan orientasi yang variatif [8]. Penggunaan variasi ini menjadikan model lebih terlatih untuk mengenali stroberi dalam berbagai kondisi. Beberapa contoh gambar hasil proses augmentasi ditampilkan juga pada Gambar 3(b).

2.1.2 Model Klasifikasi Objek

Pada tahap ini, terdapat dua metode yang dapat dilakukan untuk mengidentifikasi tingkat kematangan dan kualitas buah stroberi, yaitu metode pelatihan model dengan *deep learning*, serta penilaian langsung oleh ahli. Metode pertama melibatkan penggunaan model yang telah dilatih untuk mengenali karakteristik kematangan dan kualitas stroberi. sementara itu metode kedua melibatkan evaluasi manual oleh ahli untuk menilai kondisi buah stroberi secara langsung yang ditunjukkan pada Gambar 4.

Penggunaan metode *deep learning* dalam identifikasi tingkat kematangan dan kualitas melibatkan beberapa tahapan. Tahap pertama, dataset stroberi akan dilatih menggunakan YOLOv7 dilakukan untuk memudahkan pelatihan dataset menggunakan YOLOv7. Proses pelatihan model klasifikasi ini mencakup pelatihan pada badan stroberi yang telah di-crop menggunakan YOLOv7, sehingga model dapat lebih mudah dilatih karena dataset yang diberikan seragam dan berfokus pada badan stroberi saja. Tahap kedua, dataset hasil pelatihan YOLOv7 diteruskan untuk *preprocessing* data yang meliputi *resize*, *flip* dan *rotate* menggunakan model EfficientNetV2S. Setelah dataset melewati tahap *preprocessing* akan menghasilkan model klasifikasi dengan label kelas yang telah ditentukan. Sedangkan pada tahap evaluasi ahli, buah stroberi dinilai secara subjektif yang mengakibatkan variasi kelas yang tidak konsisten untuk kematangan dan kualitas buah stroberi.



Gambar 4. Proses Latih Model Klasifikasi

EfficientNetV2S adalah model klasifikasi yang digunakan dalam penelitian ini karena memungkinkan modifikasi pada layer defaultnya. Model yang terpilih adalah EfficientNetV2S, dipilih karena memiliki bobot yang lebih ringan daripada varian lainnya, sehingga dapat meningkatkan kecepatan pemrosesan[9].

2.2 Cloud Computing

Layanan *cloud computing* digunakan untuk mengimplementasikan model *deep learning* pada aplikasi Android dengan menggunakan *Google Cloud Platform* (GCP). Dalam penerapannya *google cloud* menyediakan berbagai layanan infrastruktur seperti *compute engine* yang dapat menjalankan *virtual machine* pada operasi Windows dan Linux. Berbagai macam layanan yang ditawarkan oleh GCP dapat disesuaikan dengan kebutuhan pengguna seperti penyimpanan data, pengembangan aplikasi, pembuatan jaringan privasi dan masih banyak yang lainnya. Layanan yang digunakan pada pembuatan aplikasi ini adalah *compute engine* dan *VPC network*. Layanan *compute engine* digunakan untuk penyedia *virtual machine* yang dapat mengimplementasikan model *deep learning* serta mengatur konfigurasi *virtual machine* seperti jenis sistem operasi, jumlah CPU, besar memori dan kapasitas penyimpanan yang diperlukan. Layanan *VPC network* digunakan untuk membuat dan mengelola jaringan *private virtual* di lingkungan *virtual machine* seperti alokasi IP serta *firewall*.

2.2.1 Virtual Machine (VM) Instances

Virtual Machine Instances adalah mesin virtual yang berjalan di dalam infrastruktur Google. GCP dapat membuat instance atau grup instance yang terkelola dengan menggunakan console *google cloud*, *google cloud CLI*, atau *compute Engine API* [10]. VM yang dibuat akan membantu proses menjalankan *application programming interface* (API) sehingga proses klasifikasi akan lebih cepat pada aplikasi.

2.2.2 Protocol Secure Shell (SSH) Keys

SSH keys adalah layanan yang digunakan untuk memastikan otentikasi yang aman saat mengakses VM. Kunci publik dihasilkan kemudian ditambahkan ke metadata SSH, dengan menggunakan metadata pengguna dapat memiliki akses untuk mengkonfigurasi, mengontrol dan mengakses informasi penting pada VM.

2.2.3 Flask

Flask merupakan kerangka kerja (*framework*) web yang fleksibel ditulis dengan bahasa pemrograman python dan serta dapat mengontrol aplikasi agar dapat mendeteksi buah stroberi dengan cepat. Pengembangan *flask* yang dibuat berbasis HTTP prosesnya dilakukan adalah permintaan dan respons antara client dan server yang terkemuka dalam ekosistem python. *Flask* yang dibuat menyediakan metode yang menghasilkan respons diantaranya GET, POST, PUT dan DELETE. Dari keempat metode yang telah tersedia, sistem yang telah dirancang menggunakan dua metode saja yaitu GET dan POST.

2.2.4 Virtual Private Cloud (VPC) Network

Layanan digunakan selanjutnya untuk mengimplementasikan machine learning dalam GCP adalah *VPC network*. *VPC network* digunakan untuk membuat dan mengelola jaringan *cloud* pribadi dalam infrastruktur Google, dengan menggunakan VPC pengguna dapat mengontrol konfigurasi jaringan seperti alamat IP, *subnet*, *routing* dan *firewall*. Pada *VPC network* ada 2 bagian penting yaitu alamat IP dan *firewall*.

2.3 Mobile Application

Produk akhir yang dibuat adalah aplikasi yang dapat mengidentifikasi tingkat kematangan dan kualitas buah stroberi menggunakan *deep learning*. Aplikasi yang akan dikembangkan didesain menggunakan perangkat lunak desain yaitu Figma, untuk memvisualisasikan konsep dan alur kerja aplikasi sebelum implementasi. Selanjutnya aplikasi akan dikembangkan menggunakan IDE IntelliJ.

2.3.1 IntelliJ IDEA

IntelliJ IDEA merupakan *Integrated Development Environment* (IDE) dari JetBrains Company dan dilisensikan oleh Apache 2.0. IntelliJ IDEA memungkinkan pengguna untuk mengembangkan aplikasi untuk beberapa platform menggunakan plugin untuk memilih fitur khusus yang dibutuhkan [11]. IDE ini digunakan untuk membangun aplikasi deteksi tingkat kematangan dan kualitas buah stroberi dengan memanfaatkan framework Flutter dan bahasa pemrograman dart.

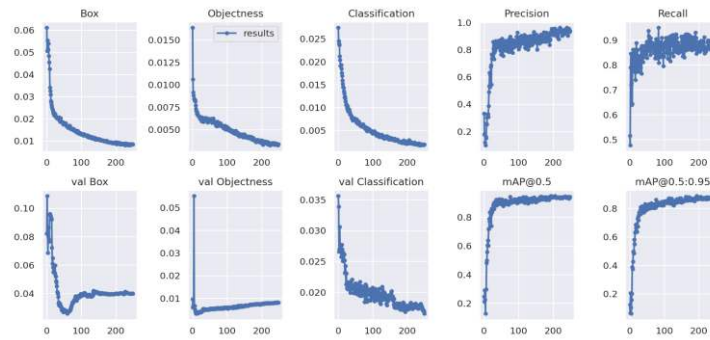
2.3.2 Android Studio

Android Studio merupakan IDE yang digunakan untuk membangun aplikasi pada *platform* Android. Android Studio menyediakan alat untuk membangun aplikasi setiap jenis Android [11]. Namun, pada penggunaannya pada pengembangan aplikasi deteksi tingkat kematangan dan kualitas pada buah stroberi, Android Studio digunakan sebagai emulator untuk mengembangkan aplikasi yang direalisasikan menggunakan IntelliJ IDEA.

3. Hasil dan Analisa

3.1 Deep Learning

Berikut adalah hasil pengukuran yang telah dilakukan, kinerja model deteksi objek selama proses pelatihan diukur menggunakan berbagai metrik deteksi objek. Metrik tersebut meliputi *box*, *objectness*, *classification*, *precision*, *recall*, dan *mAP*




Gambar 5. Hasil Evaluasi Model YOLOv7 Deteksi Objek pada saat pelatihan

Gambar 5. adalah hasil dari evaluasi model YOLOv7 sebagai deteksi objek dengan menggunakan *epoch* 250. Model menunjukkan performa deteksi objek yang baik dengan nilai *box loss* dan *val box loss* masing-masing 0,02095 dan 0,03029, serta *objectness loss* dan *val objectness loss* sebesar 0,004057 dan 0,00333. Nilai *classification loss* dan *val classification loss* sebesar 0,008343 dan 0,007392 menunjukkan kemampuan model dalam membedakan kelas-kelas objek. Nilai *precision* 0,9661 dan *recall* 0,9486, model dapat mengklasifikasikan objek secara benar dan meminimalkan kesalahan *false positive* dan *false negative*. Selain itu, nilai *mAP@0.5* sebesar 0,9788 dan *mAP@0.5-0.95* sebesar 0,9112 mengindikasikan bahwa model memiliki akurasi tinggi dalam deteksi objek dalam berbagai kondisi. selanjutnya adalah hasil pengujian model klasifikasi dapat dilihat pada Tabel 1. sebagai berikut.

Tabel 1. Hasil Pelatihan Model Klasifikasi

Class	Maturity	Quality	Precision	Recall	F1-Score
FRA	Fully Ripe	Grade-A	1,000	0,950	0,974
FRB	Fully Ripe	Grade-B	0,952	1,000	0,975
HRA	Half Ripe	Grade-A	1,000	1,000	1,000
HRB	Half Ripe	Grade-B	1,000	1,000	1,000
UR	Unripe	-	1,000	1,000	1,000
Average			0,990	0,990	0,990

Pada Tabel 1. adalah hasil pelatihan model klasifikasi dengan menggunakan *epoch* sebanyak 50. Hasil pelatihan model klasifikasi Secara keseluruhan memperoleh nilai rata-rata *Precision*, *Recall*, dan *F1-Score* sebesar 0,990. Hasil ini menunjukkan bahwa kinerja model dalam mengklasifikasi semua kelas pada buah stroberi sangat baik. Selanjutnya, hasil performansi *accuracy* dan *loss* ditampilkan pada grafik Gambar 7. sebagai berikut.



Gambar 6. Hasil Accuracy dan Loss model klasifikasi

Pada Gambar 6. merupakan hasil *accuracy* dan *loss* pada model klasifikasi yang menunjukkan bahwa grafik dalam proses model klasifikasi secara signifikan meningkatkan stabilitas dan konsistensi kinerja dari model. Grafik *accuracy* yang terus meningkat seiring bertambahnya *epoch* menunjukkan bahwa model semakin baik dalam melakukan klasifikasi dengan benar. Sementara itu, penurunan grafik *loss* menggambarkan bahwa kesalahan klasifikasi model semakin berkurang, mencerminkan peningkatan kemampuan model dalam mempelajari pola dari data latihannya.

3.2 Cloud Computing

Metode yang digunakan dalam pengujian ini masih menggunakan metode POST untuk mengirimkan gambar ke *cloud*. Pengujian dilakukan dengan menggunakan 10 gambar buah stroberi di setiap kelasnya pada *cloud* sehingga akan menampilkan *confidence* dan waktu pemrosesan baik untuk YOLOv7 dan EfficientNetV2S.

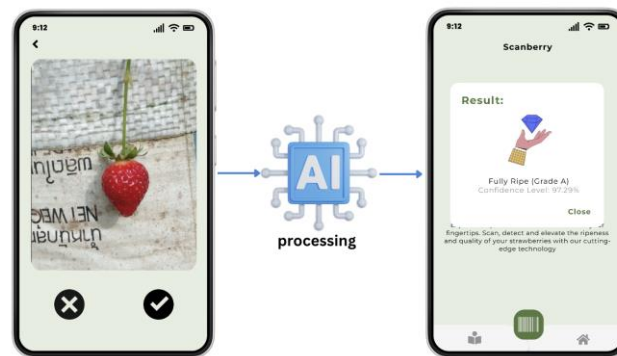
Tabel 2. Hasil Pengujian Klasifikasi Stroberi pada *Cloud*

No	Class	Status	Average Classification Result	Average Processing Time	
				YOLOv7 (ms)	EfficientNetV2S (ms)
1	FRA	Successful	0.9928	2109.57	182.3
2	FRB	Successful	0.9763	2110.62	181.3
3	HRA	Successful	0.9998	1971.48	187.6
4	HRB	Successful	0.9576	2060.9	179.4
5	UR	Successful	0.9984	1981.86	181.9

Berdasarkan Tabel 2. sistem klasifikasi menunjukkan hasil yang sangat memuaskan dengan tingkat keberhasilan yang tinggi. Semua kelas berhasil diklasifikasikan dengan status "Sukses." Rata-rata hasil klasifikasi tertinggi diperoleh pada kelas HRA dengan skor 0,9998, diikuti oleh kelas UR dengan skor 0,9984, dan kelas FRA dengan skor 0,9928. Kelas FRB dan HRB masing-masing memiliki rata-rata hasil klasifikasi sebesar 0,9763 dan 0,9576. Sementara itu, untuk waktu pemrosesan model YOLOv7 menunjukkan rata-rata waktu pemrosesan antara 1971,48 milidetik hingga 2110,62 milidetik. Kelas HRA memiliki waktu pemrosesan tercepat dengan 1971,48 milidetik. Selain itu, model EfficientNetV2S memiliki rata-rata waktu pemrosesan antara 179,4 milidetik hingga 187,6 milidetik, dengan kelas HRB sebagai yang tercepat dengan 179,4 milidetik.

3.3 Mobile Application

Aplikasi yang dikembangkan untuk deteksi dan klasifikasi buah stroberi adalah aplikasi Scanberry berikut ilustrasi aplikasi yang dikembangkan:



Gambar 7. Ilustrasi aplikasi yang dikembangkan

Pengujian *mobile application* dilakukan dengan dua jenis pengujian, sebagai berikut:

3.3.1 Pengujian Fungsionalitas Fungsionalitas Aplikasi

Pada pengujian fungsionalitas aplikasi, dilakukan dua jenis pengujian yaitu pengujian lama waktu proses aplikasi dan pengujian fitur utama menggunakan metode *black box*. Pengujian lama waktu proses bertujuan mengukur seberapa cepat aplikasi dapat memproses dan menampilkan hasil klasifikasi buah stroberi pada layar *smartphone* pengguna. Sedangkan pengujian fitur utama menggunakan metode *black box* bertujuan untuk memastikan fitur utama berjalan dengan baik dan sesuai harapan.

Pada pengujian lama waktu proses aplikasi, stroberi diklasifikasikan ke dalam lima kelas, yaitu FRA: Matang *Grade A*, FRB: Matang *Grade B*, HRA: Matang *Grade A*, HRB: Matang *Grade B* dan UR: Tidak Matang. Setiap kelas dilakukan pengujian dengan menggunakan 10 sampel buah stroberi. Pada pengujian durasi FRA: Matang *Grade A*, didapatkan rata-rata waktu pemrosesan selama 4,32 detik, pada pengujian durasi FRB: Matang *Grade B* didapatkan rata-rata waktu pemrosesan selama 4,104 detik, pada pengujian durasi HRA: Setengah Matang *Grade A* didapatkan rata-rata waktu pemrosesan selama 3,67 detik, pada pengujian HRB: Setengah Matang *Grade B* didapatkan rata-rata waktu pemrosesan selama 3,901 detik dan pada pengujian durasi UR: Tidak Matang didapatkan rata-rata waktu pemrosesan selama 3,597 detik. Hasil pengujian ini menunjukkan bahwa waktu pemrosesan rata-rata bervariasi antara 3,597 detik hingga 4,32 detik dan menunjukkan kemampuan untuk memberikan hasil klasifikasi yang cepat.

Pada fitur utama menggunakan metode *black box* menunjukkan bahwa fitur berjalan dengan baik dan lancar. Pengujian ini mencakup beberapa tugas yang perlu diselesaikan untuk memastikan fungsi fitur aplikasi beroperasi dengan baik dan sesuai dengan yang diharapkan. Berdasarkan pengujian yang telah dilakukan menunjukkan fitur utama berjalan dengan baik dan lancar sesuai dengan hasil yang diharapkan pada skenario pengujian yang diberikan. Berdasarkan pengujian yang telah dilakukan, menunjukkan bahwa aplikasi tidak hanya cepat dalam memproses data tetapi juga berfungsi dengan baik dan sesuai dengan harapan pengguna.

3.3.2 Pengujian Perangkat Lunak Aplikasi

Pengujian perangkat lunak aplikasi meliputi tiga aspek yaitu *Usability Testing*, *Compatibility Testing* dan *Performance Testing* yang bertujuan untuk mengukur kinerja aplikasi di lingkungan sebenarnya.

a. Usability Testing

Pada pengujian *usability testing*, tugas-tugas diberikan sebagai panduan untuk menguji aplikasi, dan setelah menyelesaikan tugas-tugas tersebut, pengguna diminta untuk mengisi kuesioner yang telah disiapkan. Berdasarkan hasil pengujian, didapatkan nilai rata-rata untuk aspek sistem sebesar 4,805, nilai rata-rata untuk aspek pengguna (*user*) sebesar 4,76 dan nilai rata-rata untuk aspek interaksi sebesar 4,84. Hal ini menunjukkan bahwa aplikasi Scanberry memiliki performa yang sangat baik di berbagai aspek pengamatan. Pada aspek sistem, pengguna merasa aplikasi berjalan dengan lancar dan dapat berjalan sesuai dengan fungsinya. Pada aspek pengguna (*user*), pengguna juga merasa bahwa aplikasi ini sangat membantu dan mudah dipahami. Selain itu, pada aspek interaksi, pengguna merasa tampilan aplikasi menarik, mudah digunakan dan efisien.

b. Compatibility Testing

Berdasarkan *compatibility testing* yang telah dilakukan pada beberapa versi Android yang berbeda didapatkan bahwa aplikasi Scanberry dapat di instalasi pada Android versi 8.0 Oreo hingga Android 14. Selain itu, aplikasi mampu beroperasi dengan baik dan lancar serta mampu menjalankan berbagai tugas yang telah ditentukan pada *usability testing*. Hal ini menunjukkan, aplikasi dapat berjalan dengan baik pada tidak hanya pada versi Android lama tetapi juga pada versi terbaru.

c. Performance Testing

Pada *performance testing* dilakukan dengan mengukur penggunaan CPU aplikasi, CPU perangkat, memori aplikasi dan memori perangkat. Berdasarkan *performance testing* ini didapatkan penggunaan CPU aplikasi mencapai 153% pada saat fitur 'Scan Image' dibuka hingga mengirimkan data dari galeri foto ke *cloud*. Selanjutnya, penggunaan CPU perangkat mencapai 505% pada saat yang sama saat menggunakan fitur *scan image*. Selain itu, penggunaan CPU perangkat mencapai 759% pada proses pengiriman gambar melalui kamera langsung. Penggunaan CPU yang tinggi ini menunjukkan adanya pemrosesan data kompleks yang terjadi namun penggunaan CPU aplikasi tetap dalam batas aman.

Pada *performance testing* memori, memori aplikasi dan perangkat menunjukkan grafik yang stabil namun konsisten meningkat yang ditunjukkan pada Gambar 5.28. dan 5.29. Penggunaan memori aplikasi tertinggi tercatat sebesar 420,26 MB dan memori perangkat sebesar 6947,41 MB, penggunaan memori meningkat pada saat fitur 'Scan Image' dioperasikan yang menunjukkan adanya pemrosesan data yang kompleks sehingga membutuhkan memori yang besar.

4. Kesimpulan

Pengujian yang telah dilakukan terhadap *deep learning*, *cloud computing* dan *mobile application* menunjukkan bahwa aplikasi yang telah dibuat berhasil melakukan klasifikasi tingkat kematangan dan kualitas buah stroberi dengan akurasi yang tinggi 90% dan waktu pemrosesan yang dibutuhkan sangat cepat dengan durasi sekitar 3-4 detik. Pengujian keseluruhan fitur utama pada aplikasi menggunakan metode *blackbox* menunjukkan bahwa aplikasi berhasil menjalankan fungsi fitur dengan baik. Hasil uji kuantitatif yang dilakukan dengan memberikan para pengguna untuk mengisi kuesioner menjadi indikator penting untuk menunjukkan bahwa aplikasi dapat digunakan bagi para pengguna, berdasarkan hasil yang diperoleh sekitar 24-30 pengguna aplikasi memberikan nilai 5 untuk setiap pertanyaan, hal ini menunjukkan bahwa aplikasi Scanberry dapat menjadi aplikasi baik dalam melakukan klasifikasi buah stroberi.

Pengembangan selanjutnya diharapkan dapat mengumpulkan lebih banyak data (dataset) dengan variasi yang lebih banyak agar memastikan model bekerja dengan baik dalam klasifikasi buah stroberi dalam berbagai kondisi. Selain itu, meningkatkan model *deep learning* dengan mencoba berbagai arsitektur dan teknik terbaru untuk meningkatkan akurasi dan efisiensi aplikasi dalam melakukan klasifikasi buah stroberi. Pada pengembangan selanjutnya disarankan mengintegrasikan aplikasi dengan sistem manajemen pertanian dan platform IoT untuk mendukung pemantauan yang lebih menyeluruh sehingga lebih membantu dalam proses pemilihan buah secara banyak.

Berdasarkan hasil yang diperoleh diharapkan Scanberry dapat membantu petani dan pengunjung dalam memilih buah stroberi sesuai dengan referensi yang mereka inginkan. Aplikasi Scanberry dapat terus berkontribusi dalam meningkatkan proses sortir buah stroberi lebih efisien dan menghemat waktu para petani bekerja. Implementasi aplikasi ini tidak hanya mempercepat proses penyortiran, tetapi juga meningkatkan konsistensi dan kualitas produk yang dihasilkan, sehingga memberikan nilai tambah bagi petani dan memastikan kepuasan pelanggan. Scanberry memiliki potensi besar untuk menjadi alat penting dalam industri pertanian stroberi untuk mendukung keberlanjutan dan peningkatan produktivitas secara keseluruhan.

Daftar Pustaka:

- [1] F. Cosme *et al.*, "Red Fruits Composition and Their Health Benefits—A Review," *Foods*, vol. 11, no. 5. MDPI, Mar. 01, 2022. doi: 10.3390/foods11050644.
- [2] Badan Pusat Statistik, "Produksi Tanaman Buah-buahan 2022," DataBoks. Accessed: Oct. 31, 2023. [Online]. Available: <https://www.bps.go.id/indicator/55/62/1/produksi-tanaman-buah-buahan.html>
- [3] M. M. Rahman, M. Moniruzzaman, M. R. Ahmad, B. C. Sarker, and M. Khurshid Alam, "Maturity stages affect the postharvest quality and shelf-life of fruits of strawberry genotypes growing in subtropical regions," *Journal of the Saudi Society of Agricultural Sciences*, vol. 15, no. 1, pp. 28–37, Jan. 2016, doi: 10.1016/j.jssas.2014.05.002.

- [4] H. Zhou, J. Ou, P. Meng, J. Tong, H. Ye, and Z. Li, "Research on Kiwi Fruit Flower Recognition for Efficient Pollination Based on an Improved YOLOv5 Algorithm," *Horticulturae*, vol. 9, no. 3, Mar. 2023, doi: 10.3390/horticulturae9030400.
- [5] Y. Fan, S. Zhang, K. Feng, K. Qian, Y. Wang, and S. Qin, "Strawberry Maturity Recognition Algorithm Combining Dark Channel Enhancement and YOLOv5," *Sensors*, vol. 22, no. 2, Jan. 2022, doi: 10.3390/s22020419.
- [6] D. Antony and A. N. Fajar, "Object detection using convolutional neural network YOLOv7 to detect banana ripeness," *J Theor Appl Inf Technol*, vol. 31, no. 6, 2024.
- [7] Suharjito et al., "Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning," *Sci Data*, vol. 10, no. 1, Dec. 2023, doi: 10.1038/s41597-023-01958-x.
- [8] N. Aherwadi, U. Mittal, J. Singla, N. Z. Jhanjhi, A. Yassine, and M. S. Hossain, "Prediction of Fruit Maturity, Quality, and Its Life Using Deep Learning Algorithms," *Electronics (Switzerland)*, vol. 11, no. 24, Dec. 2022, doi: 10.3390/electronics11244100.
- [9] M. Tan and Q. V Le, "EfficientNetV2: Smaller Models and Faster Training," 2021. [Online]. Available: <https://github.com/google/> [Accessed: March 26, 2023].
- [10] IBM, "What is a REST API?" IBM. Accessed: March 26, 2023. [Online]. Available: <https://www.ibm.com/topics/rest-apis>.
- [11] J. Redmon, "Getting Started with Roboflow," *Roboflow Blog*, 2020. [Online]. Available: <https://blog.roboflow.com/getting-started-with-roboflow/> [Accessed: March. 25, 2024]
- [12] D. A. Anam, L. Novamizanti, & S. Rizal, "Klasifikasi Patologi Makula Pada Retina Berdasarkan Citra Retinal OCT Menggunakan Convolutional Neural Network (Classifying Retinal Pathology Using OCT Retinal Imaging With Convolutional Neural Network)," vol. 8, hal. 5064-5071.
- [13] H. M. Lathifah, L. Novamizanti, & S. Rizal, "Fast and accurate fish classification from underwater video using you only look once," in *IOP Conference Series: Materials Science and Engineering*, vol. 982, no. 1, pp. 012003). IOP Publishing, December 2020.
- [14] F. Akhyar, L. Novamizanti, T. Putra, E. N. Furqon, M. C. Chang, & C. Y. Lin, "Lightning YOLOv4 for a surface defect detection system for sawn lumber," in *2022 IEEE 5th International Conference on Multimedia Information Processing and Retrieval (MIPR)* (pp. 184-189). IEEE, August 2022.
- [15] F. Akhyar, L. Novamizanti, & T. Riantiarni, "Sistem inspeksi cacat pada permukaan kayu menggunakan model deteksi obyek YOLOv5," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no.4, pp. 990, 2022.
- [16] A. K. Aziz, M. D. Maulana, R. F. Adawiyah, R. F. Firdaus, L. Novamizanti, & F. Ramdhon, "Comparative analysis of YOLOv8 models in skipjack fish quality assessment system," in *2023 3rd International Conference on Intelligent Cybernetics Technology & Applications (ICICyTA)* (pp. 237-242). IEEE, December 2023.
- [17] S. Azizah, Wahidin, M. Padang, L. Novamizanti, S Saidah. "Identifying the Ripeness and Quality Level of Strawberries Based on YOLOv7-EfficientNet." *The 5th International Conference on Data Science and Its Applications (ICoDSA)*. IEEE, July 2024.
- [18] B. A. Wicaksono, L. Novamizanti, & N. Ibrahim, "Tea leaf maturity levels based on ycbcr color space and clustering centroid," In *Journal of Physics: Conference Series* (Vol. 1367, No. 1, pp. 012028). IOP Publishing, November 2019.