

# **Sistem Estimasi Tingkat Kematangan Buah Melon Menggunakan *Machine Learning***

**BAHARUDIN HASAN<sup>1</sup>, SETIAWARDHANA<sup>1</sup>, AGUS INDRA GUNAWAN<sup>2</sup>, ARNA FARIZA<sup>1</sup>**

<sup>1</sup>Departemen Teknik Informatika dan Komputer, Politeknik Elektronika Negeri Surabaya, Indonesia

<sup>2</sup>Departemen Teknik Elektro, Politeknik Elektronika Negeri Surabaya, Indonesia

Email : setia@pens.ac.id<sup>1</sup>

*Received* 8 Agustus 2025 | *Revised* 15 Desember 2025 | *Accepted* 5 Januari 2026

## **ABSTRAK**

*Penentuan tingkat kematangan buah melon sangat penting untuk menjaga kualitas dan daya simpan. Metode tradisional yang bergantung pada penilaian visual, penciuman, dan mengetuk buah bersifat subjektif dan tidak konsisten. Penelitian ini mengusulkan sistem estimasi usia dan tingkat kematangan buah melon berbasis citra dengan metode Faster R-CNN menggunakan backbone ResNet-50. Dataset sebanyak 1.683 citra melon dikumpulkan dari kebun hidroponik, kemudian melalui proses anotasi, preprocessing, dan augmentasi sebelum digunakan untuk pelatihan model. Evaluasi kinerja dilakukan menggunakan mean Average Precision (mAP), precision, recall, F1-score, dan accuracy. Hasil pengujian menunjukkan akurasi 92,42%, F1-score 0,890, dan mAP (0.5:0.95) sebesar 0,828. Sistem ini mampu mendeteksi objek melon serta mengklasifikasikan tingkat kematangan menjadi tiga kategori dengan lebih objektif dibandingkan metode tradisional.*

**Kata kunci:** *Machine Learning, Faster R-CNN, Kematangan Buah Melon, Pengolahan Citra, Deteksi Objek*

## **ABSTRACT**

*The determination of melon fruit maturity is crucial for maintaining quality and shelf life. Traditional methods that rely on visual assessment, smell, and tapping the fruit are subjective and inconsistent. This study proposes an image-based system for estimating the age and maturity level of melons using the Faster R-CNN method with a ResNet-50 backbone. A dataset of 1,683 melon images was collected from a hydroponic farm and subsequently processed through annotation, preprocessing, and augmentation before being used for model training. Performance evaluation was conducted using mean Average Precision (mAP), precision, recall, F1-score, and accuracy. The experimental results demonstrated an accuracy of 92.42%, an F1-score of 0.890, and an mAP (0.5:0.95) of 0.828. The proposed system is capable of detecting melon objects and classifying maturity levels into three categories more objectively than traditional methods.*

**Keywords:** *Machine Learning, Faster R-CNN, Melon Ripeness, Image Processing, Object Detection*

## 1. PENDAHULUAN

Melon (*Cucumis melo L.*) merupakan tanaman hortikultura yang termasuk dalam famili labu-labuan dan banyak dibudidayakan di negara tropis, khususnya Indonesia **(Saputra dkk., 2022)**. Buah ini memiliki nilai gizi yang tinggi karena mengandung vitamin C, mineral, dan beta-karoten yang bermanfaat bagi kesehatan **(Yuliawan & Firmansyah, 2023)**. Secara umum, terdapat tiga varietas utama melon, yaitu *reticulatus*, *inodorus*, dan *cantalupensis*, yang masing-masing memiliki perbedaan pada bentuk, warna kulit, dan tekstur permukaan buah **(Zakiah dkk., 2023)**.

Penentuan tingkat kematangan merupakan faktor penting sebelum proses panen karena sangat berpengaruh terhadap kualitas buah yang dihasilkan **(Rizzo dkk., 2023)**. Kematangan dapat diamati dari sifat fisikokimia, misalnya tekstur daging buah yang semakin lunak seiring bertambahnya umur **(Wahyudi dkk., 2020)**. Namun, metode tradisional yang umum digunakan petani seperti penilaian visual, pemeriksaan aroma, maupun mengetuk buah untuk mendengarkan resonansinya, sering kali bersifat subjektif dan tidak konsisten **(Fitria dkk., 2023)**. Kondisi tersebut dapat menyebabkan buah dipanen terlalu dini sehingga menghasilkan rasa yang kurang aromatik, atau dipanen terlambat yang berdampak pada menurunnya daya simpan **(Vanoli dkk., 2023)**.

Prediksi waktu panen yang lebih akurat sangat dibutuhkan untuk memastikan buah melon sampai ke konsumen dalam kualitas terbaik dan daya simpan **optimal (Pamungkas & Bintoro, 2021)**. Untuk mengatasi keterbatasan metode tradisional, teknologi pengolahan citra digital dapat dimanfaatkan untuk menganalisis parameter visual seperti warna, tekstur, dan bentuk buah secara lebih objektif. Dengan dukungan algoritma *machine learning* dan *deep learning* seperti Faster R-CNN, sistem estimasi kematangan dapat dikembangkan untuk mendeteksi objek dan mengklasifikasi tingkat kematangan buah secara otomatis.

Sejumlah penelitian telah dilakukan untuk mengestimasi tingkat kematangan buah melon dengan pendekatan berbasis analisis citra. Tawakal dan Prayoga mengembangkan metode deteksi kematangan menggunakan tekstur kulit buah dengan kombinasi Histogram of *Oriented Gradients* (HOG) dan *Support Vector Machine* (SVM). Dengan memanfaatkan 450 citra melon, metode tersebut mencapai akurasi 78,67% **(Abidzar Tawakal & Prayoga, 2019)**. Qian dkk. mengusulkan model prediksi panen melon berdasarkan 32 variabel fitur yang mencakup aspek fenologis, bentuk, dan warna. Metode *Gradient Boosted Decision Tree* (GBDT) dan *Grid Search* digunakan untuk membangun model prediksi yang memungkinkan estimasi langsung di lapangan tanpa merusak buah melon **(Qian dkk., 2022)**. Penelitian lain oleh Saputra dkk. menggunakan *Gray Level Co-occurrence Matrix* (GLCM) untuk analisis tekstur yang dikombinasikan dengan SVM pada 650 citra melon. Hasil menunjukkan bahwa penggunaan kernel *linear* pada SVM dengan delapan arah GLCM menghasilkan akurasi terbaik sebesar 80% dengan *precision* 81% dan *recall* 80% **(Saputra dkk., 2022)**.

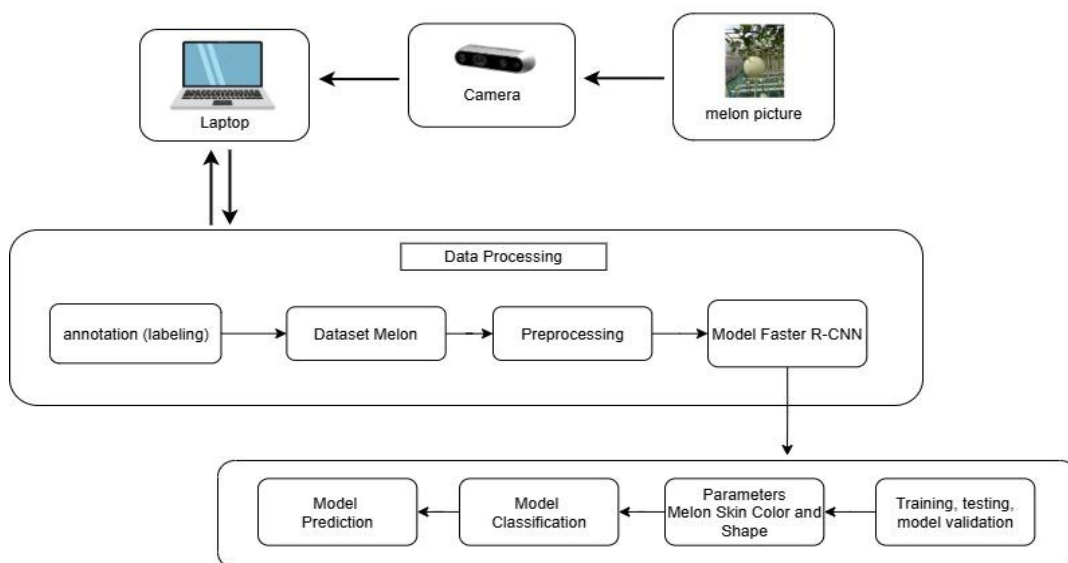
Selain itu, Yuliawan dan Firmansyah mengembangkan prototipe sistem penyortiran kualitas melon berdasarkan tekstur kulit dengan memanfaatkan *Local Binary Pattern* (LBP) dan algoritma *K-Nearest Neighbor* (KNN). Sistem ini diuji pada varietas *Sky Rocket* dengan 200 sampel dan berhasil mencapai tingkat keberhasilan sebesar 96% **(Yuliawan & Firmansyah, 2023)**. Di sisi lain, Kasih dkk. mengusulkan metode *non-destruktif* berbasis impuls akustik untuk memprediksi sifat fisikokimia buah melon. Data frekuensi dominan, magnitudo, *zero-moment power*, dan *short-term energy* diproses menggunakan jaringan saraf tiruan berbasis *Backpropagation*. Model yang dihasilkan menunjukkan performa yang sangat baik dengan nilai  $R^2$  di atas 0,92 dan *Mean Squared Error* (MSE) yang relatif rendah **(Kasih dkk., 2024)**.

Dalam perkembangan metode visi komputer modern, berbagai pendekatan *deep learning* telah digunakan untuk mendeteksi dan mengklasifikasikan tingkat kematangan buah. Di antara metode tersebut, Faster R-CNN menunjukkan performa yang lebih unggul dibandingkan algoritma satu tahap seperti YOLO maupun pendekatan tradisional (**Restrepo-Arias dkk., 2025**). Keunggulan ini terutama terlihat pada akurasi deteksi, kemampuan lokalisasi objek yang presisi, serta ketahanan terhadap variasi warna, tekstur halus, dan kondisi lapangan yang kompleks. Dengan dukungan arsitektur dua tahap serta *backbone* seperti ResNet dan FPN, Faster R-CNN mampu mengekstraksi fitur multi-skala secara lebih efektif, sehingga lebih andal dalam membedakan tingkat kematangan buah (**Chen dkk., 2024**).

Penelitian ini mengembangkan sistem estimasi tingkat kematangan buah melon berbasis citra lapangan yang diambil secara berkala setiap tiga hari di kebun hidroponik, sehingga membentuk dataset *time-series* yang merepresentasikan perubahan visual melon dari mentah hingga matang. Pelabelan kematangan dilakukan berdasarkan konsistensi perubahan visual tersebut, sehingga lebih objektif. Kontribusi utama penelitian ini adalah pengembangan sistem berbasis visi komputer yang mampu melakukan deteksi dan klasifikasi kematangan melon secara langsung dari citra lapangan, dengan memanfaatkan variasi dataset yang mengikuti perkembangan buah setiap tiga hari. Pendekatan ini menawarkan solusi yang lebih praktis, objektif, dan dapat diterapkan secara *real-time* untuk mendukung keputusan waktu panen pada budidaya melon hidroponik.

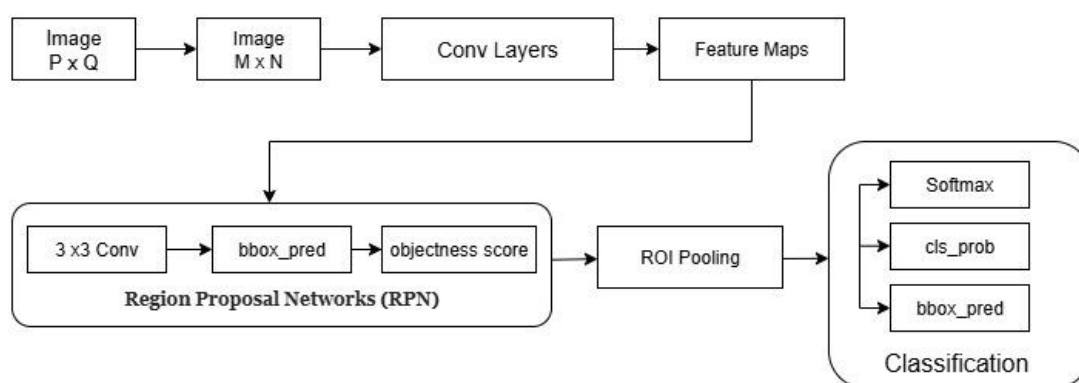
## 2. METODE PENELITIAN

Penelitian ini membangun sistem untuk memperkirakan tingkat kematangan buah dan usia tanam berdasarkan citra melalui serangkaian tahapan utama, dimulai dari pengumpulan dataset citra buah melon pada kebun hidroponik, anotasi objek buah melon pada citra, preprocessing citra untuk memastikan kualitas data, pelatihan model menggunakan metode Faster R-CNN, dan evaluasi performa model untuk klasifikasi tingkat kematangan. Perancangan sistem estimasi tingkat kematangan buah berdasarkan citra dalam penelitian ini dapat dilihat pada Gambar 1 berikut:



Gambar 1. Diagram Penelitian

Faster R-CNN adalah algoritma yang dikembangkan dengan mengacu pada metode sebelumnya, yakni *R-CNN* dan *Fast R-CNN*, dengan memanfaatkan *Convolutional Neural Network* (CNN) sebagai dasar utama dari algoritma tersebut (**Pardede & Hardiansah, 2022**). Faster R-CNN diperkenalkan oleh Shaoqing Ren untuk menciptakan algoritma yang dapat mendeteksi objek dan melakukan klasifikasi dengan cepat. Metode ini menggantikan *Selective Search* (SS), yang sebelumnya digunakan untuk menentukan *Regions of Interest* (RoI) dalam proses deteksi objek (**Wang & Xiao, 2023**). Meskipun *Selective Search* efektif, penggunaannya menimbulkan *bottleneck* yang memperlambat proses komputasi. Untuk mengatasi hal ini, Faster R-CNN menggantikan *Selective Search* dengan *Regional Proposal Network* (RPN), yang meningkatkan efisiensi deteksi objek (**Rahman & Bambang, 2021**).




**Gambar 2. Arsitektur Faster R-CNN**

Metode Faster R-CNN terdiri dari tiga komponen utama, yaitu lapisan konvolusi, *Region Proposal Network* (RPN), dan klasifikasi. Pada tahap pertama, filter dilatih untuk mengekstraksi fitur penting dari gambar. Selanjutnya, pada tahap kedua, gambar yang telah diproses dengan filter dimasukkan ke dalam RPN untuk memprediksi *bounding box* dari gambar tersebut. Tahap ketiga melibatkan prediksi klasifikasi berdasarkan *input* yang telah dimasukkan (**Septian & Septanto, 2022**). Pertama, gambar  $P \times Q$  dengan berbagai ukuran diskalakan ke ukuran tetap  $M \times N$  dan dikirim ke lapisan *Conv* untuk mengekstrak *feature map*. *feature map* ini kemudian digunakan untuk lapisan RPN dan *layer fully connected* berikutnya. *feature map* tersebut kemudian dimasukkan ke dalam *Region Proposal Network* (RPN) untuk menghasilkan *Region of Interest* (ROIs). RPN menggunakan *softmax* untuk mengklasifikasikan apakah jangkar termasuk dalam kategori positif atau negatif, kemudian memperbaiki jangkar untuk memperoleh proposal yang lebih akurat melalui regresi *bounding box* (**Pang dkk., 2024**). *layer Roi Pooling* mengumpulkan *feature map* dan proposal dari *input*, mengintegrasikan informasi tersebut untuk mengekstraksi *feature map* proposal, dan kemudian mengirimkannya ke *layer fully connected* untuk menentukan kategori objek. Terakhir, bagian klasifikasi menghitung kategori dari proposal berdasarkan peta fitur proposal, serta memperoleh posisi tepat dari deteksi frame melalui regresi *bounding box* pada saat yang bersamaan (**Li, 2021**).

## 2.1. Pengumpulan Data

Proses pengambilan citra di kebun hidroponik dilakukan secara manual setiap tiga hari sekali untuk memperoleh data representatif mengenai perubahan tingkat kematangan buah selama satu siklus panen. Sebanyak 15 tanaman melon digunakan sebagai sampel, dan setiap buah difoto dari tiga sudut berbeda atas, samping, dan bawah untuk memberikan informasi visual yang lebih lengkap serta meminimalkan bias akibat sudut pandang tertentu. Kamera

dipasang pada rangka dan diarahkan sesuai posisi yang ditentukan agar kualitas citra konsisten, dengan pengambilan gambar diulang secara teratur hingga akhir panen. Seluruh citra yang diperoleh kemudian dijadikan dataset untuk melatih model *deep learning* dalam klasifikasi tingkat kematangan buah melon, sebagaimana ditunjukkan pada Gambar 3 yang menampilkan contoh hasil pengambilan citra di kebun hidroponik.



**Gambar 3. Sample Dataset**

Setelah proses pengambilan selesai, citra yang terkumpul dikelompokkan ke dalam tiga tingkat kategori kematangan, yakni mentah, setengah matang, dan matang. Pengelompokan ini didasarkan pada usia tanaman serta informasi dari petani hidroponik sebagai acuan. Untuk memberikan gambaran visual, contoh citra dari setiap kategori ditunjukkan pada Gambar 4 - 6 masing-masing mewakili buah melon mentah, setengah matang, dan matang.



**Gambar 4. Melon Mentah**



**Gambar 5. Melon Setengah Matang**



**Gambar 6. Melon Matang**

Pengambilan citra dilakukan dari tiga sudut berbeda atas, samping, dan bawah untuk memberikan variasi informasi visual mengenai buah melon. Dari ketiga sudut tersebut, citra samping cenderung menghasilkan tampilan buah yang lebih utuh dan jelas, sementara sudut atas sering terhalang dedaunan dan sudut bawah lebih dipengaruhi oleh pencahayaan. Berdasarkan pertimbangan tersebut, hanya citra dari sudut samping dan bawah yang

digunakan dalam penyusunan dataset agar kualitas visual tetap konsisten dan relevan untuk proses klasifikasi. Secara keseluruhan terkumpul 990 citra yang terbagi ke dalam tiga kategori tingkat kematangan, dengan distribusi data seperti yang tertera pada Tabel 1.

**Tabel 1. Distribusi Data**

Kelas	Jumlah Data
Mentah	360
Setengah Matang	300
Matang	330

## 2.2. Anotasi Citra

Langkah berikutnya adalah proses anotasi citra menggunakan *Roboflow*, yang bertujuan untuk memberikan label pada setiap gambar berdasarkan kategori kematangan buah (mentah, setengah matang, matang). Anotasi dilakukan dengan membuat *bounding box* di sekitar objek buah dan memberikan label yang sesuai dengan tingkat kematangannya. Dataset yang telah diberi *anotasi* tersebut selanjutnya digunakan untuk melatih model pembelajaran mesin, agar model dapat mengenali fitur visual yang membedakan tiap tingkat kematangan dengan akurat. Dalam penelitian ini, *Roboflow* menghasilkan file anotasi berformat JSON, yang berisi informasi label kelas serta koordinat *bounding box* ( $x$ ,  $y$ , lebar, dan tinggi) dalam nilai absolut. Format ini sesuai dengan kebutuhan arsitektur Faster R-CNN, yang memerlukan koordinat presisi untuk mendeteksi dan mengklasifikasikan objek pada tahap pelatihan model. Ilustrasi berikut menampilkan tahapan anotasi citra yang dilakukan dengan bantuan aplikasi *Roboflow*.



**Gambar 7. Citra Asli**



**Gambar 8. Anotasi Citra**

Berdasarkan Gambar 7 adalah citra asli sebelum *anotasi* dilakukan, sementara Gambar 8 menunjukkan citra setelah proses anotasi, dapat dilihat bahwa anotasi untuk Faster R-CNN disusun dalam format JSON. Setiap berkas anotasi berisi informasi mengenai nama file citra, dimensi citra (*width* dan *height*), serta detail *bounding box* yang mencakup koordinat titik awal ( $x, y$ ), lebar, tinggi, dan label kelas objek. Sebagai contoh, pada gambar 8 ditunjukkan bahwa objek diberi label "Matang" dengan koordinat *bounding box* sesuai posisi buah pada citra. Informasi ini menjadi referensi utama bagi model Faster R-CNN dalam tahap pelatihan untuk mendeteksi dan mengenali objek dengan akurasi yang tepat.

### 2.3. Preprocessing Data

Tahap setelah anotasi adalah *preprocessing* dan *augmentasi* yang bertujuan untuk memastikan kualitas data tetap konsisten sekaligus memperkaya variasi dataset. Pada tahap *preprocessing*, setiap citra terlebih dahulu melalui proses *auto-orient* untuk menyesuaikan orientasi gambar agar tidak ada citra yang terbalik atau salah arah. Selanjutnya, citra di *resize* menjadi ukuran seragam 640×640 piksel. Pemilihan ukuran ini dilakukan untuk menyeimbangkan antara detail gambar yang cukup dengan efisiensi pemrosesan, sehingga model dapat belajar dengan optimal tanpa terbebani komputasi yang berlebihan.

Selain itu, proses *augmentasi* dilakukan untuk meningkatkan kemampuan model dalam melakukan generalisasi terhadap berbagai kondisi di dunia nyata. *Augmentasi* yang diterapkan meliputi rotasi 90° baik searah jarum jam maupun berlawanan arah jarum jam, rotasi terbalik (*upside down*) antara  $-15^\circ$  hingga  $+15^\circ$ , serta penyesuaian tingkat kecerahan dalam rentang  $-15\%$  hingga  $+15\%$ . Teknik-teknik ini membantu memperkaya variasi data sehingga model tetap dapat mengenali buah melon meskipun terdapat perbedaan sudut pandang, posisi, maupun kondisi pencahayaan. Setelah *preprocessing* dan *augmentasi*, dataset akhir terdiri dari 1.683 citra, yang terbagi menjadi data pelatihan, validasi, dan pengujian sebagaimana terlihat pada Tabel 2.

**Tabel 2. Jumlah Dataset**

Data	Jumlah
Train	1386
Valid	198
Test	99

### 2.4. Pembuatan Model (Faster R-CNN)

Penelitian ini menggunakan metode Faster R-CNN untuk mengklasifikasikan tingkat kematangan buah melon ke dalam tiga kategori: mentah, setengah matang, dan matang. Pertama, dataset disiapkan dalam format COCO (*Common Objects in Context*), di mana setiap citra dilengkapi berkas anotasi JSON yang memuat label kelas dan koordinat *bounding box*, kemudian diatur menggunakan *DataLoader* untuk pelatihan dan validasi model. Sebagai *backbone*, digunakan ResNet-50 yang didukung *Feature Pyramid Network* (FPN) untuk meningkatkan kemampuan deteksi objek pada berbagai skala. Konfigurasi ini mencakup tiga kelas utama buah melon ditambah satu kelas latar belakang, sehingga model dapat digunakan untuk mengklasifikasikan tingkat kematangan buah melon secara lebih spesifik.

Tahap berikutnya adalah mendefinisikan *optimizer* dan *scheduler* untuk mengatur proses pelatihan model. *Optimizer* berfungsi memperbaiki parameter model berdasarkan *gradien* yang dihasilkan, sementara *scheduler* mengatur laju pembelajaran (*learning rate*) secara dinamis agar pelatihan lebih stabil. Pada penelitian ini digunakan *Stochastic Gradient Descent* (SGD) menggunakan parameter yang tercantum pada Tabel 3.

**Tabel 3. Parameter *Optimizer* dan *Scheduler***

Komponen	Parameter	Nilai
<i>Optimizer</i>	<i>Learning rate</i>	0.005
	<i>Momentum</i>	0.9
	<i>Weight decay</i>	0.0005
<i>Scheduler</i>	<i>Step size</i>	3
	<i>Gamma</i>	0.1

## 2.5 Pelatihan Model

Proses pelatihan dilakukan dengan menjalankan Faster R-CNN selama 10 *epoch* Menggunakan *Google Colab* sebagai *platform* komputasi dengan dukungan GPU, sehingga proses pelatihan model dapat berlangsung lebih cepat. Pada setiap *epoch*, model memproses data pelatihan, dan melakukan *backpropagation* untuk memperbarui bobot serta bias menggunakan *optimizer*. Selanjutnya, *learning rate scheduler* digunakan untuk mengatur laju pembelajaran secara bertahap agar proses konvergensi lebih stabil. Hasil pelatihan disimpan secara berkala setelah setiap *epoch* untuk memastikan model terdokumentasi dan dapat digunakan kembali pada tahap evaluasi.

## 2.6 Metrik Evaluasi

Untuk mengevaluasi kinerja model dalam mendeteksi dan mengklasifikasikan objek, penelitian ini mengaplikasikan berbagai metrik evaluasi standar yang umum digunakan dalam tugas deteksi objek (**Gong & Zhang, 2023**). *Mean Average Precision* (mAP) digunakan untuk mengukur rata-rata akurasi model dalam mendeteksi objek pada berbagai tingkat ambang batas *Intersection over Union* (IoU) (**Xiao dkk., 2020**). Metrik mAP@IoU=0.5:0.95, menghitung akurasi pada rentang IoU dari 0.5 hingga 0.95, sehingga memberikan gambaran kemampuan model pada berbagai tingkat kesesuaian dengan *ground truth*. Sedangkan mAP@IoU=0.5 hanya mempertimbangkan deteksi yang memiliki tumpang tindih minimal 50% dengan *ground truth* (**Yao dkk., 2024**).

Selain mAP, kinerja model juga dinilai menggunakan *Precision*, yang mengukur proporsi deteksi yang benar dari total deteksi yang dilakukan oleh model, dirumuskan sebagai Persamaan (1):

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

*Recall* digunakan untuk menghitung proporsi objek yang berhasil dideteksi dari seluruh objek yang ada, dengan Persamaan (2):

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

Selanjutnya, *F1-score* dihitung sebagai rata-rata harmonik antara *precision* dan *recall* untuk memberikan ukuran kinerja yang seimbang, sesuai Persamaan (3):

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (3)$$

Selanjutnya, *Accuracy* digunakan untuk mengetahui proporsi prediksi yang benar dari seluruh prediksi, dengan Persamaan (4):

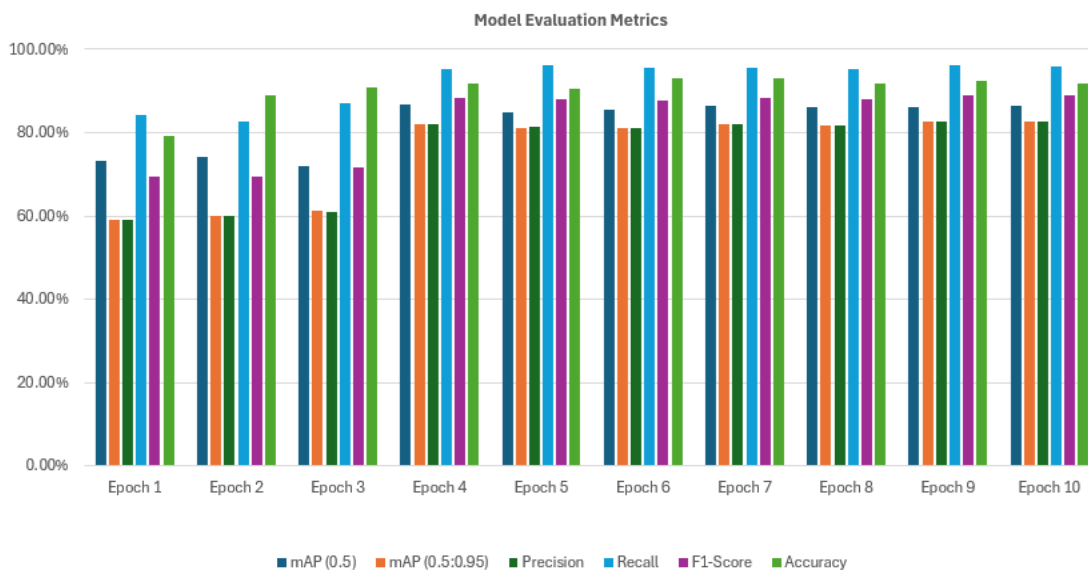
$$Accuracy = \frac{TP+TN}{Total\ Sample\ Count} \tag{4}$$

Metrik-metrik ini digunakan secara bersama-sama untuk mengevaluasi performa model dalam mendeteksi objek dengan tingkat akurasi yang optimal, meminimalkan deteksi palsu, dan menjaga keseimbangan antara *precision* dan *recall*.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Evaluasi Model

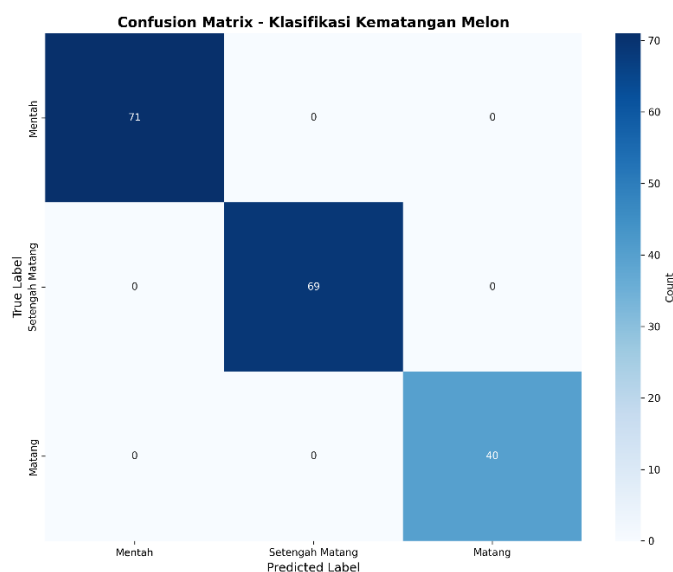
Untuk mengevaluasi performa model Faster R-CNN, dilakukan pengujian pada sepuluh iterasi pelatihan yang berbeda, di mana setiap iterasi disimpan dalam bentuk file *.pth* untuk menentukan model dengan hasil paling optimal yang digunakan dalam proses prediksi terhadap citra uji. Gambar 9 menunjukkan hasil evaluasi model berdasarkan beberapa metrik, yaitu mAP (0.5), mAP (0.5:0.95), *precision*, *recall*, *F1-score*, dan *accuracy*. Melalui evaluasi ini dapat dianalisis tren peningkatan performa model seiring bertambahnya iterasi pelatihan. Selanjutnya, untuk menilai lebih dalam kemampuan model dalam membedakan setiap kategori kematangan, digunakan *confusion matrix* sebagai evaluasi. Gambar 10 merupakan hasil *confusion matrix* yang memberikan gambaran menyeluruh mengenai kesesuaian antara label prediksi dan label sebenarnya pada setiap kelas, sehingga memudahkan dalam melihat tingkat ketepatan prediksi serta potensi kesalahan klasifikasi yang mungkin terjadi.



**Gambar 9. Model Evaluation Metrics**

Berdasarkan Gambar 9, terlihat adanya peningkatan signifikan pada seluruh metrik evaluasi seiring bertambahnya iterasi pelatihan. Model Path ke-9 menunjukkan performa terbaik secara keseluruhan dengan nilai mAP (0.5:0.95) sebesar 0.828, *Precision* 0.828, *Recall* 0.962, *F1-score* 0.890, dan *Accuracy* 92.42%. Akurasi ini dihitung berdasarkan proporsi prediksi deteksi yang benar (*true positives* dan *true negatives*) terhadap total prediksi model pada dataset uji, sehingga mencerminkan sejauh mana sistem mampu menghasilkan *bounding box* dan label kelas yang tepat. Meskipun *Path* ke-6 dan ke-7 mencatat akurasi sedikit lebih tinggi (92.93%), *Path* ke-9 tetap unggul karena memberikan keseimbangan terbaik antara mAP, *F1-score*, dan kemampuan generalisasi deteksi. Analisis ini menegaskan

bahwa model dengan mAP dan  $F1$ -score yang seimbang cenderung menghasilkan performa deteksi yang lebih stabil, sehingga *Path* ke-9 dipilih sebagai model final untuk pengujian lebih lanjut.



**Gambar 10. Confusion Matrix**





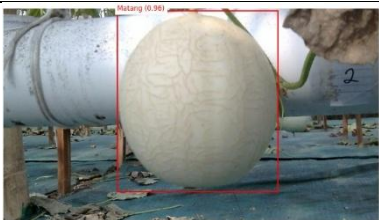

Berdasarkan Gambar 10, hasil *confusion matrix* menunjukkan bahwa model mampu mengklasifikasikan seluruh sampel uji secara tepat tanpa terjadi kesalahan prediksi antar kelas. Hal ini ditunjukkan oleh nilai diagonal matriks yang tinggi (Mentah = 71, Setengah Matang = 69, Matang = 40) serta nilai *off-diagonal* yang bernilai nol.

### 3.2 Pengujian Model

Setelah menentukan model terbaik dari evaluasi, pengujian dilakukan untuk menilai kemampuan Faster R-CNN dengan *backbone* ResNet-50 dalam mendeteksi kategori kematangan buah melon: Mentah, Setengah Matang, dan Matang. Proses pengujian ini menggunakan dataset uji yang berbeda dari data pelatihan, untuk memastikan model dapat menggeneralisasi deteksi pada kondisi nyata.

Prediksi model dianalisis berdasarkan *bounding boxes*, label, dan skor deteksi, di mana hanya prediksi dengan skor di atas ambang batas 0.5 yang ditampilkan. Hasil pengujian menunjukkan bahwa model mampu mendeteksi dan mengklasifikasikan kematangan buah dengan baik. Prediksi untuk kategori Mentah, Setengah Matang, dan matang dapat dilihat pada Tabel 4. Kotak pembatas yang ditampilkan sesuai dengan posisi objek dalam citra, dan label menunjukkan kategori kematangan yang terdeteksi, sehingga memudahkan evaluasi visual terhadap akurasi prediksi model.

**Tabel 4. Pengujian Model**

Kategori	Gambar		Probabilitas Prediksi	
	Depan	Bawah	Depan	Bawah
Mentah			95%	99%
Setengah Matang			89%	93%
Matang			96%	92%

Pada Tabel 4, ditampilkan hasil prediksi model untuk kategori Mentah. Dari gambar ini menunjukkan bahwa model dapat mengklasifikasikan objek dengan tepat, dengan skor deteksi masing-masing 95% gambar dari depan dan 99% gambar dari bawah. Nilai skor yang tinggi ini menunjukkan tingkat kepercayaan model terhadap deteksi yang dilakukan, sehingga *bounding boxes* yang dihasilkan dapat diandalkan untuk menandai lokasi buah yang benar-benar mentah. Kategori selanjutnya yaitu hasil prediksi model untuk kategori Setengah Matang. Model berhasil mengidentifikasi objek dengan tepat, dengan skor deteksi masing-masing 89% gambar dari depan dan 93% gambar dari bawah, menandakan tingkat kepercayaan yang tinggi terhadap prediksi yang dilakukan. *Bounding boxes* yang dihasilkan menunjukkan posisi buah yang akurat, sehingga kategori Setengah Matang dapat dibedakan dengan jelas dari kategori lainnya. Sedangkan hasil prediksi model untuk kategori Matang. Model berhasil mendeteksi dan mengklasifikasikan buah dengan akurasi tinggi, ditunjukkan oleh skor deteksi yaitu 96% untuk gambar dari depan dan 92% gambar dari bawah. Hasil ini memperlihatkan bahwa model mampu mengenali buah yang benar-benar matang dengan tingkat keyakinan yang kuat, sehingga klasifikasi kategori Matang dapat dilakukan secara andal.

### 3.3 Pembahasan dan Kontribusi

Berdasarkan hasil evaluasi, penggunaan serangkaian metrik seperti *mAP*, *Precision*, *Recall*, *F1-score*, dan *Accuracy* memberikan pemahaman yang komprehensif mengenai performa model dalam mendeteksi sekaligus mengklasifikasikan tingkat kematangan buah melon. Nilai *mAP* yang tinggi pada model menunjukkan bahwa kemampuan deteksi kotak objek (*bounding box*) berada pada tingkat konsistensi yang baik di seluruh kelas kematangan. Hal

ini mengindikasikan bahwa fitur visual seperti warna kulit dan kerapatan pola netting berhasil ditangkap dengan baik oleh *backbone ResNet-50* sebagai representasi yang relevan. Keseimbangan antara *Precision* dan *Recall* menggambarkan karakteristik performa yang tidak hanya akurat, tetapi juga sensitif. *Precision* yang tinggi menandakan model jarang melakukan kesalahan deteksi (*false positive*), sedangkan *Recall* yang sangat tinggi mengindikasikan bahwa objek melon dalam berbagai variasi kondisi pencahayaan dan fase pertumbuhan tetap berhasil terdeteksi (*false negative*). Nilai *F1-score* kemudian memperkuat interpretasi ini dengan menunjukkan keseimbangan optimal antara kedua metrik tersebut, yang penting ketika sistem diharapkan stabil pada data lapangan yang memiliki variabilitas lebih tinggi.

Evaluasi terhadap sepuluh model pada berbagai *path* pelatihan memperlihatkan tren peningkatan performa seiring bertambahnya iterasi. Model pada *Path* ke-9 menunjukkan performa paling optimal dengan mAP (0.5:0.95) sebesar 0.828, *Precision* 0.828, *Recall* 0.962, *F1-score* 0.890, dan *Accuracy* 92.42%. Meskipun *Path* ke-6 dan ke-7 mencatat nilai *Accuracy* sedikit lebih tinggi, model *Path* ke-9 memberikan keseimbangan terbaik pada seluruh metrik utama, terutama pada mAP dan *F1-score* yang menjadi indikator penting dari kemampuan generalisasi. Temuan ini menunjukkan bahwa kualitas model tidak hanya ditentukan oleh akurasi, tetapi oleh konsistensi performa pada berbagai *threshold* IoU (pada mAP) dan stabilitas keseimbangan *Precision-Recall* (pada *F1-score*). Dengan demikian, *Path* ke-9 lebih layak dianggap sebagai model yang paling representatif.

Analisis visual pada Tabel 4 menunjukkan bahwa model Faster R-CNN dengan *backbone ResNet-50* mampu melakukan deteksi dan klasifikasi tingkat kematangan secara konsisten pada setiap kategori. Hal ini terlihat dari skor *confidence* yang relatif tinggi untuk kelas Mentah, Setengah Matang, maupun Matang, tanpa menunjukkan kecenderungan bias pada salah satu kelas. Hasil ini relevan mengingat dataset diambil berdasarkan interval tiga hari dari fase awal hingga panen, sehingga variasi fitur visual cukup beragam. Namun demikian, penelitian ini masih memiliki beberapa keterbatasan. Variasi dataset, terutama dari sisi sudut pengambilan gambar, latar belakang, dan kondisi pencahayaan, masih terbatas sehingga kemampuan generalisasi model pada kondisi lapangan yang sangat variatif perlu diuji lebih lanjut.

Selain itu, optimasi lanjutan seperti *augmentasi* intensif, *fine-tuning hyperparameter*, atau penambahan data dari musim tanam berbeda berpotensi meningkatkan *robustness* model. Dari sisi kontribusi, penelitian ini memberikan nilai tambah pada tiga aspek utama. Pertama, penelitian ini menunjukkan adaptasi efektif dari arsitektur Faster R-CNN untuk domain pertanian, khususnya dalam klasifikasi tingkat kematangan buah secara otomatis. Kedua, penggunaan dataset kustom yang diperoleh langsung dari kebun hidroponik dengan interval pengambilan setiap tiga hari memperkuat relevansi penelitian pada konteks *real-world monitoring*. Ketiga, penggunaan evaluasi *multimetric* memastikan bahwa performa model tidak hanya baik pada satu indikator, tetapi stabil pada seluruh metrik yang mewakili ketepatan, sensitivitas, dan generalisasi.

#### 4. KESIMPULAN

Penelitian ini mengusulkan pengembangan sistem estimasi usia dan tingkat kematangan buah melon berbasis citra dengan menerapkan metode *deep learning* Faster R-CNN dengan *backbone ResNet-50* untuk ekstraksi fitur. Sistem ini dirancang tidak hanya untuk mendeteksi objek melon pada citra yang diambil langsung dari kebun hidroponik, tetapi juga untuk mengklasifikasikan tingkat kematangannya ke dalam tiga kategori, yaitu mentah,

setengah matang, dan matang. Dataset yang digunakan diperoleh secara berkala setiap tiga hari sekali selama fase pertumbuhan buah, kemudian dianotasi secara manual dan diperluas melalui proses *augmentasi* hingga mencapai 1.683 citra yang digunakan dalam pelatihan, validasi, dan pengujian model.

Hasil pengujian menunjukkan bahwa model Faster R-CNN mampu memberikan performa deteksi yang tinggi, dengan nilai akurasi terbaik sebesar 92.42%, *F1-score* sebesar 0.890, serta mAP (0.5:0.95) mencapai 0.828. Capaian ini menegaskan bahwa pendekatan berbasis *deep learning*, khususnya Faster R-CNN dengan ResNet-50, menawarkan metode yang lebih objektif, stabil, dan andal dibandingkan pendekatan tradisional dalam menentukan tingkat kematangan dan prediksi waktu panen buah melon, penelitian ini dapat dikembangkan lebih lanjut dengan memperluas variasi dataset pada berbagai varietas melon, memperkaya variasi kondisi lingkungan dan sudut pengambilan gambar, menambahkan parameter *non-visual* seperti data sensor lingkungan, serta menguji sistem dalam skenario lapangan secara *real-time*. Dengan demikian, sistem ini berpotensi menjadi bagian dari teknologi pertanian presisi yang mendukung produktivitas dan kualitas hasil panen secara berkelanjutan.

#### DAFTAR RUJUKAN

- Abidzar Tawakal, H., & Prayoga, A. (2019). The Development of Methods for Detecting Melon Maturity Level Based on Fruit Skin Texture Using the Histogram of Oriented Gradients and the Support Vector Machine. *2019 Fourth International Conference on Informatics and Computing (ICIC)*, 1–4. <https://doi.org/10.1109/ICIC47613.2019.8985953>
- Chen, G., Hou, Y., Cui, T., Li, H., Shangguan, F., & Cao, L. (2024). YOLOv8-CML: A lightweight target detection method for color-changing melon ripening in intelligent agriculture. *Scientific Reports*, *14*(1), 14400. <https://doi.org/10.1038/s41598-024-65293-w>
- Fitria, M., Candra, Y., Al-Assad, M. H., Roza, S., & Dawood, R. (2023). A Deep Learning-Based Model for Classifying Sweetness Level of Sky Rocket Melon: A Preliminary Result. *2023 2nd International Conference on Computer System, Information Technology, and Electrical Engineering (COSITE)*, 204–209. <https://doi.org/10.1109/COSITE60233.2023.10250114>
- Gong, X., & Zhang, S. (2023). A High-Precision Detection Method of Apple Leaf Diseases Using Improved Faster R-CNN. *Agriculture*, *13*(2), 240. <https://doi.org/10.3390/agriculture13020240>
- Kasih, A. N., Khuriyati, N., & Falah, A. F. (2024). Prediksi fisikokimia melon (Cucumis melo L.) secara non-destruktif dengan impuls akustik dan jaringan saraf tiruan. *Agrointek: Jurnal Teknologi Industri Pertanian*, *18*(3), 733–741. <https://doi.org/10.21107/agrointek.v18i3.21746>

- Li, W. (2021). Analysis of Object Detection Performance Based on Faster R-CNN. *Journal of Physics: Conference Series*, 1827(1), 012085. <https://doi.org/10.1088/1742-6596/1827/1/012085>
- Pamungkas, W. A., & Bintoro, N. (2021). Karakteristik Kematangan Buah Melon 'Premier' (Cucumis Melo L.) Berdasarkan Sifat akustik. *Agrointek: Jurnal Teknologi Industri Pertanian*, 15(3), 715–727. <https://doi.org/10.21107/agrointek.v15i3.9621>
- Pang, W., Ma, Y., Jiang, H., & Yu, Q. (2024). Cells Grouping Detection and Confusing Labels Correction on Cervical Pathology Images. *Bioengineering*, 12(1), 23. <https://doi.org/10.3390/bioengineering12010023>
- Pardede, J., & Hardiansah, H. (2022). Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16. *MIND Journal*, 7(1), 21–36. <https://doi.org/10.26760/mindjournal.v7i1.21-36>
- Qian, C., Du, T., Sun, S., Liu, W., Zheng, H., & Wang, J. (2022). An integrated learning algorithm for early prediction of melon harvest. *Scientific Reports*, 12(1), 18199. <https://doi.org/10.1038/s41598-022-20799-z>
- Rahman, M. F., & Bambang, B. (2021). Deteksi Sampah pada Real-time Video Menggunakan Metode Faster R-CNN. *Applied Technology and Computing Science Journal*, 3(2), 117–125. <https://doi.org/10.33086/atcsj.v3i2.1846>
- Restrepo-Arias, J. F., Montoya-Castaño, M. J., Moreno-De La Espriella, M. F., & Branch-Bedoya, J. W. (2025). An Application of Deep Learning Models for the Detection of Cocoa Pods at Different Ripening Stages: An Approach with Faster R-CNN and Mask R-CNN. *Computation*, 13(7), 159. <https://doi.org/10.3390/computation13070159>
- Rizzo, M., Marcuzzo, M., Zangari, A., Gasparetto, A., & Albarelli, A. (2023). Fruit ripeness classification: A survey. *Artificial Intelligence in Agriculture*, 7, 44–57. <https://doi.org/10.1016/j.aiia.2023.02.004>
- Saputra, R. A., Puspitasari, D., & Baidawi, T. (2022). Deteksi Kematangan Buah Melon dengan Algoritma Support Vector Machine Berbasis Ekstraksi Fitur GLCM. 4(2). <https://doi.org/10.31294/infortech.v4i2.14436.g5734>
- Septian, I., & Septanto, H. (2022). Pengembangan Model Pendeteksian Gambar Alat Musik dengan Metode Faster R-CNN dengan Library Keras. 8(1).
- Vanoli, M., Cortellino, G., Picchi, V., Buccheri, M., Grassi, M., Lovati, F., Marinoni, L., Levoni, P., Torricelli, A., & Spinelli, L. (2023). Non-destructive determination of ripening in melon fruit using time-resolved spectroscopy. *Advances in Horticultural Science*, 37(1), 75–82. <https://doi.org/10.36253/ahsc-13943>

- Wahyudi, I., Haryanto, & Ulum, M. (2020). *Rancang Bangun Alat Penentuan Tingkat Kematangan Buah Melon Dengan Sensor Max9814 dan Sensor Soil Moisture Menggunakan Logika Fuzzy*.
- Wang, H., & Xiao, N. (2023). Underwater Object Detection Method Based on Improved Faster RCNN. *Applied Sciences*, *13*(4), 2746. <https://doi.org/10.3390/app13042746>
- Xiao, Y., Wang, X., Zhang, P., Meng, F., & Shao, F. (2020). Object Detection Based on Faster R-CNN Algorithm with Skip Pooling and Fusion of Contextual Information. *Sensors*, *20*(19), 5490. <https://doi.org/10.3390/s20195490>
- Yao, G., Zhu, S., Zhang, L., & Qi, M. (2024). HP-YOLOv8: High-Precision Small Object Detection Algorithm for Remote Sensing Images. *Sensors*, *24*(15), 4858. <https://doi.org/10.3390/s24154858>
- Yuliawan, R. A., & Firmansyah, R. A. (2023). Prototype of Melon Fruit Quality Sorter Based on Skin Texture Using Local Binary Pattern Histogram. *Jurnal Ecotipe (Electronic, Control, Telecommunication, Information, and Power Engineering)*, *10*(2), 152–160. <https://doi.org/10.33019/jurnalecotipe.v10i2.4476>
- Zakiah, R. A., Wahjuni, S., & Suwarno, W. B. (2023). Pemilihan Algoritma Machine Learning untuk Perangkat dengan Komputasi Terbatas pada Deteksi Kematangan Buah Melon Berjala. *Jurnal Ilmu Komputer dan Agri-Informatika*, *10*(2), 189–199. <https://doi.org/10.29244/jika.10.2.189-199>