

KLASIFIKASI KEMATANGAN ALPUKAT HASS MENGGUNAKAN YOLO V8 BERDASARKAN 5 TAHAP KEMATANGAN

Teuku Vaickal Rizki Irdian, Nila Hardi, Minda Septiani

Informatika, Universitas Bina Sarana Informatika

Jakarta, Indonesia

15220658@bsi.ac.id

ABSTRAK

Alpukat Hass merupakan komoditas pertanian dengan permintaan yang tinggi; namun, penilaian tingkat kematangannya secara manual sebagian besar bersifat subjektif, memakan banyak tenaga, dan rentan terhadap ketidakkonsistenan. Untuk mengatasi keterbatasan ini, penelitian ini mengembangkan sistem *computer vision* otomatis menggunakan arsitektur YOLOv8-cls untuk mengklasifikasikan tingkat kematangan alpukat Hass secara akurat ke dalam lima tahap yang mendetail. Metodologi penelitian ini memanfaatkan *dataset* komprehensif sebanyak 14.710 citra digital yang dikategorikan secara sistematis ke dalam tahap *Unripe*, *Breaking*, *Ripe (First Phase)*, *Ripe (Second Phase)*, dan *Over-ripe*. Performa prediktif model dievaluasi secara ketat menggunakan metrik klasifikasi standar, khususnya *Overall Accuracy*, *Precision*, *Recall*, dan analisis *Confusion Matrix*, untuk menilai kemampuannya dalam membedakan tahapan kelas dengan ambiguitas visual yang tinggi. Hasil eksperimen menunjukkan bahwa model YOLOv8-cls mencapai akurasi klasifikasi yang tangguh sebesar 84,97%, dengan *precision* sebesar 84,39% dan *recall* sebesar 84,27%. Lebih lanjut, analisis *confusion matrix* memberikan wawasan penting yang membuktikan keandalan model dalam meminimalkan kesalahan klasifikasi pada tahap transisi yang saling berdekatan, serta mencapai performa puncak pada tahap ekstrem seperti *Unripe* (94%) dan *Over-ripe* (92%). Secara praktis, sistem otomatis ini menawarkan solusi yang terukur (*scalable*) dan sangat akurat untuk rantai pasokan pertanian, sehingga memungkinkan para petani, distributor, dan konsumen untuk menilai kualitas alpukat secara objektif dan efisien.

Kata kunci : *computer vision, deep learning, hass avocado, image classification, ripeness assessment, yolov8*

1. PENDAHULUAN

Alpukat Hass (*Persea americana*) merupakan komoditas pertanian yang bernilai ekonomi tinggi secara global, yang dibedakan oleh nilai gizinya yang tinggi dan sifat pematangan klimakteriknya [1]. Karena proses pematangan terus berlanjut secara dinamis pascapanen, pembentukan manajemen rantai pasokan yang optimal sangat penting untuk memitigasi kerusakan dini dan kehilangan pangan (*food loss*) [2]. Secara historis, evaluasi tingkat kematangan alpukat didominasi oleh protokol penyortiran manual. Metode tradisional ini sangat bergantung pada penilaian visual manusia terhadap warna kulit khususnya transisi dari hijau menjadi hitam keunguan yang dikombinasikan dengan pengujian kekerasan fisik [3]. Sebagai contoh, penelitian oleh [4] mengeksplorasi estimasi kematangan alpukat menggunakan pantulan ultraviolet, meskipun metode tersebut mungkin memerlukan perangkat keras khusus yang kurang dapat diakses untuk aplikasi lapangan secara *real-time*. Akibatnya, paradigma konvensional ini bersifat sangat subjektif, memakan banyak tenaga (*labor-intensive*), dan pada dasarnya rentan terhadap kesalahan klasifikasi (*misclassification*), terutama ketika membedakan fase kematangan yang saling berdekatan, seperti perubahan visual yang samar antara tahap *breaking* dan tahap awal *ripe*.

Untuk mengatasi inefisiensi dari inspeksi manual, sektor pertanian semakin banyak mengadopsi teknologi *Computer Vision* dan *Artificial Intelligence*

(AI) [5]. Dalam ranah ini, *Convolutional Neural Networks* (CNNs) telah membangun fondasi yang kuat untuk sistem penyortiran buah otomatis [5]. Di antara arsitektur kontemporer yang ada, algoritma *You Only Look Once* versi 8 (YOLOv8) memberikan keuntungan krusial dengan menyeimbangkan beban komputasi yang rendah dengan akurasi prediktif yang tinggi, sehingga memfasilitasi klasifikasi yang mendetail (*fine-grained*) secara *real-time* bahkan pada perangkat dengan sumber daya komputasi terbatas [6]. Investigasi sebelumnya telah berhasil mengadaptasi YOLOv8 untuk mengategorikan fase pematangan pada stroberi [5], mangga, dan pisang [9]. Demikian pula, varian ringan (*lightweight*) dari YOLO telah menunjukkan kemampuan generalisasi yang kuat di lingkungan kebun yang kompleks, secara akurat menilai kematangan tomat [7], nanas, buah jeruk [8], buah ceri kecil [9], buah naga [10], dan leci [11]. Lebih lanjut, optimasi melalui mekanisme atensi (*attention mechanisms*) telah terbukti meningkatkan akurasi YOLOv8 dalam mendeteksi kematangan pada melon [12] dan *rock melon* [13]. Meskipun sebagian besar penelitian berfokus pada deteksi objek, klasifikasi tahap kematangan tetap menjadi tantangan karena adanya transisi visual yang samar. Studi oleh [14] menyoroti kompleksitas klasifikasi tahapan pada tomat, dan menekankan bahwa segmentasi fitur sangat vital untuk estimasi kualitas. Penelitian ini mengatasi kesenjangan penting dengan mengimplementasikan YOLOv8-cls untuk mengklasifikasikan alpukat Hass ke dalam lima tahapan yang mendetail. Berbeda

dengan model berbasis deteksi yang memprioritaskan *Mean Average Precision* (mAP), penelitian ini berfokus pada akurasi kategorikal untuk menyelesaikan ambiguitas visual, dengan mengevaluasi model melalui *Overall Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Untuk menangani *dataset* yang padat dan pola visual yang rumit, kemajuan terbaru juga telah mengintegrasikan mekanisme atensi hibrida ke dalam *backbone* YOLOv8.

Menurut penulis, terlepas dari berbagai kemajuan teknologi tersebut, masih terdapat kesenjangan literatur yang signifikan mengenai penerapan YOLOv8 untuk menilai rangkaian pematangan yang sangat bernuansa pada alpukat Hass. Studi-studi terkait alpukat yang ada saat ini sebagian besar mengandalkan teknik pencitraan hiperspektral kompleks atau model CNN standar yang diarahkan pada deteksi kesegaran biner dan prediksi umur simpan (*shelf-life*) secara umum [1]. Meskipun model hibrida YOLO dasar telah diusulkan untuk deteksi alpukat [15], masih terdapat kekurangan nyata dalam penelitian yang mengevaluasi secara kritis arsitektur YOLOv8-cls untuk memetakan indeks pematangan lima tahap standar yang sangat mendetail dengan hanya mengandalkan citra digital RGB. Kesenjangan ilmiah ini terletak pada penyelesaian ambiguitas visual dari pola kromatik yang sangat tumpang tindih pada tahap kematangan yang saling berdekatan. Oleh karena itu, penelitian ini bertujuan untuk membangun dan mengevaluasi model klasifikasi otomatis yang tangguh untuk tingkat kematangan alpukat Hass menggunakan algoritma YOLOv8-cls. Dengan memanfaatkan *dataset* komprehensif yang terdiri dari 14.710 citra digital yang dikategorikan secara khusus ke dalam lima indeks warna visual [1], tujuan eksplisitnya adalah untuk menganalisis performa model berdasarkan *confusion matrix*, *precision*, dan *recall*. Pada akhirnya, temuan ini diharapkan dapat menghasilkan implikasi praktis yang signifikan dengan menawarkan kerangka kontrol kualitas yang sangat akurat, terukur (*scalable*), dan non-destruktif untuk operasi agribisnis pascapanen.

Sepanjang pengetahuan kami, ini merupakan penelitian pertama yang mengevaluasi YOLOv8-cls secara khusus untuk indeks pematangan lima tahap standar pada alpukat Hass dengan hanya menggunakan citra RGB, sekaligus mengatasi kesenjangan dalam analisis ambiguitas kromatik per kelas.

2. TINJAUAN PUSTAKA

2.1. Penilaian Kematangan Buah Konvensional dan Berbasis Sensor

Evaluasi tingkat kematangan buah alpukat secara tradisional sangat bergantung pada protokol penyortiran manual yang didasarkan pada perubahan warna kulit secara visual dari hijau menjadi hitam keunguan dan pengujian kekerasan fisik secara langsung [1]. Karena metode ini memakan banyak tenaga kerja dan rentan terhadap subjektivitas

manusia, berbagai pendekatan berbasis sensor telah diusulkan. Sebagai contoh, penelitian oleh Bayu & Pertiwi [4] mengeksplorasi estimasi kematangan alpukat dengan memanfaatkan teknologi pantulan ultraviolet. Selain itu, teknik pencitraan hiperspektral yang dipadukan dengan *Convolutional Neural Networks* (CNN) standar juga telah diimplementasikan oleh Xavier et al. [16] untuk prediksi umur simpan (*shelf-life*) dan deteksi kesegaran alpukat. Meskipun metode-metode tersebut menunjukkan hasil yang positif, pendekatan ini cenderung membutuhkan perangkat keras yang mahal, berfokus pada klasifikasi biner, dan kurang dapat diakses untuk aplikasi klasifikasi secara *real-time* di lapangan.

2.2. Implementasi Deep Learning pada Sektor Pertanian

Untuk mengatasi inefisiensi dari inspeksi manual dan kompleksitas sensor optik khusus, sektor pertanian mulai mengadopsi teknologi *Computer Vision* dan *Artificial Intelligence* (AI) secara masif [4]. Dalam domain ini, algoritma *You Only Look Once* versi 8 (YOLOv8) menawarkan keunggulan krusial karena mampu menyeimbangkan beban komputasi yang rendah dengan akurasi prediktif yang sangat tinggi [7]. Berbagai studi terdahulu telah membuktikan bahwa varian YOLO memiliki kemampuan generalisasi yang kuat di lingkungan kebun yang kompleks. Arsitektur ini telah berhasil diadaptasi untuk mendeteksi dan mengategorikan fase pematangan pada tomat [7], stroberi [5], mangga dan pisang [17], nanas [18], buah jeruk [19], buah ceri kecil [9], buah naga [10], hingga leci [11].

2.3. Perkembangan Arsitektur YOLOv8 dan Celah Penelitian

Meskipun pemanfaatan YOLOv8 telah meluas untuk deteksi objek, mengklasifikasikan tahapan pematangan yang saling berdekatan dan memiliki transisi visual yang samar tetap menjadi tantangan teknis. Penelitian oleh Ahmad et al. [14] menyoroti bahwa segmentasi fitur sangat vital untuk mengatasi kompleksitas klasifikasi tahapan buah. Guna menangani ambiguitas fitur tersebut, beberapa penelitian terkini mengintegrasikan mekanisme atensi (*attention mechanisms*) pada YOLOv8, yang secara signifikan mampu meningkatkan akurasi deteksi kematangan pada melon [12] dan *rock melon* [13].

Khusus pada komoditas alpukat, model YOLO hibrida dasar baru diusulkan sebatas untuk tugas deteksi keberadaan buah [13]. Menurut Kamat et al. [20], masih terdapat kesenjangan literatur yang signifikan mengenai penerapan YOLOv8 untuk menilai rangkaian pematangan yang sangat bernuansa pada alpukat Hass. Oleh karena itu, penelitian ini memposisikan diri untuk mengisi celah (*research gap*) tersebut dengan memanfaatkan varian klasifikasi (YOLOv8-cls) guna memetakan indeks kematangan alpukat ke dalam lima tahap yang sangat mendetail, murni dengan mengekstraksi fitur dari citra digital

RGB tanpa dibebani oleh evaluasi *Mean Average Precision* (mAP) dari model berbasis deteksi.

2.4. Penelitian Terdahulu


Untuk mempertegas posisi kebaruan (*novelty*) ilmiah, penelitian ini membandingkan pendekatan yang diusulkan dengan beberapa penelitian terdahulu yang relevan dalam ranah visi komputer pertanian. Pemetaan kontribusi dan perbedaan metodologi dari studi-studi terkait tersebut dirangkum pada Tabel 1.

Tabel 1. Penelitian terdahulu

No	Penulis	Objek	Metode
1	Wang et al. [5]	Stroberi	YOLOv8+
2	Prasetya et al. [18]	Nanas	Convolutional Neural Network
3	Davur et al. [3]	Alpukat	Hyperspectral Imaging
4	Xavier et al. [1]	Alpukat	Deep Learning Approaches

3. METODE PENELITIAN

Penelitian ini mengadopsi pendekatan eksperimental kuantitatif untuk mengimplementasikan dan mengevaluasi arsitektur YOLOv8-cla untuk klasifikasi tingkat kematangan buah. Eksperimen dilakukan di dalam lingkungan *Kaggle Notebooks*, dengan memanfaatkan *dual GPU NVIDIA T4*. NVIDIA T4, yang dibangun di atas arsitektur *Turing*, memiliki 2.560 *CUDA Cores* dan 16GB *GDDR6 VRAM*, serta memberikan performa FP16 sebesar 65 TFLOPS, yang memastikan efisiensi komputasi tinggi untuk pelatihan *deep learning*.



Gambar 1. Alur kerja penelitian untuk klasifikasi alpukat hass

Berdasarkan Gambar 1, dapat dilihat bahwa tahapan penelitian dimulai dari pengumpulan *dataset* hingga evaluasi model. *Dataset* yang digunakan dalam penelitian ini terdiri dari 14.710 citra digital beresolusi tinggi dari alpukat Hass, yang menangkap lima tahap kematangan yang berbeda: *Unripe*, *Breaking*, *Ripe (First Phase)*, *Ripe (Second Phase)*, dan *Over-ripe*. Sebelum fase pelatihan, seluruh citra melalui tahap pra-pemrosesan (*preprocessing*) dengan mengubah ukurannya (*resizing*) menjadi resolusi seragam 224x224 piksel dan menormalisasi nilai piksel ke rentang [0, 1] agar sesuai dengan konsistensi dimensi masukan yang dibutuhkan oleh jaringan klasifikasi YOLOv8.

Untuk mencegah kebocoran data (*data leakage*) dan memastikan evaluasi model yang tangguh, dataset dipartisi menggunakan pendekatan *stratified sampling* guna mempertahankan distribusi klasifikasi yang merata. Secara khusus, 70% (10.297 citra) dari dataset dialokasikan untuk pelatihan agar model dapat mempelajari fitur visual dari setiap tahap kematangan selama periode pelatihan yang ditentukan, yaitu 50 epoch. Selanjutnya, 20% (2.942 citra) dari data ditetapkan untuk validasi guna memantau kemampuan generalisasi model selama pelatihan, sementara 10% sisanya (1.471 citra) disisihkan sebagai set pengujian (*test set*) untuk evaluasi akhir yang tidak bias. Seluruh model dilatih dengan *batch size* sebesar 32.

Untuk mengukur performa, penelitian ini memanfaatkan metrik kategorikal yang diturunkan dari *confusion matrix*, khususnya *Overall Accuracy* (1), *Precision* (2), *Recall* (3), dan *F1-Score* (4). Definisi dan perhitungan untuk metrik-metrik tersebut ditunjukkan secara berurutan:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$


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

$$Recall = \frac{TP}{TP+FP} \quad (3)$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

4. HASIL DAN PEMBAHASAN

4.1. Persiapan Dataset




Gambar 2. Alur kerja penelitian untuk klasifikasi alpukat hass

Penelitian ini memanfaatkan dataset komprehensif yang terdiri dari 14.710 citra digital beresolusi tinggi dari buah alpukat Hass yang bersumber dari repositori publik Mendeley Data [16].

4.2. Pelatihan Model YOLOv8-cla

Eksperimen pelatihan model dilakukan di dalam lingkungan *Kaggle Notebooks* dengan memanfaatkan unit pemrosesan *dual NVIDIA T4 GPUs*. Model YOLOv8-cla dilatih selama 50 *epoch* dengan *batch size* sebesar 32. Kemajuan proses pelatihan divisualisasikan melalui kurva *loss* dan *accuracy* pada Gambar 2. Berdasarkan grafik tersebut, terlihat adanya penurunan yang konsisten pada *training loss* maupun *validation loss*, yang mengindikasikan bahwa model berhasil mencapai konvergensi dengan baik tanpa mengalami *overfitting* yang signifikan:



Gambar 3. Kemajuan pelatihan yolov8


4.3. Hasil Evaluasi Model

Performa prediktif model dievaluasi secara ketat menggunakan 1.471 citra pengujian yang belum pernah dilihat sebelumnya (*unseen test images*). Hasil eksperimen menunjukkan bahwa model YOLOv8-clc mencapai akurasi klasifikasi keseluruhan sebesar 84,97%. Nilai rata-rata makro untuk *precision* tercatat sebesar 84,39%, sedangkan *recall* berada pada angka 84,27%, yang menunjukkan kapabilitas klasifikasi yang seimbang di seluruh tingkat kematangan. Rincian performa untuk masing-masing kelas kematangan dapat dilihat pada Tabel 1:

Tabel 2. Rekapitulasi metrik performa

Tahap Kematangan	Precision	Recall	F1-Score
Unripe	94%	94%	94%
Ripe (First Phase)	74%	79%	76%
Ripe (Second Phase)	79%	74%	77%
Over-ripe	94%	92%	93%
Rata-rata makro	84%	84%	84%
Akurasi Keseluruhan			85%

Lebih lanjut, analisis *Confusion Matrix* pada Gambar 3 membuktikan bahwa model sangat tangguh dalam mengidentifikasi spektrum kematangan ekstrem, dengan tingkat akurasi mencapai 94% untuk kelas *Unripe* dan 92% untuk kelas *Over-ripe*.



Gambar 4. Perbandingan confusion matrix dan normalized confusion matrix

Untuk memvalidasi keandalan model dalam skenario pengujian riil sesuai dengan target indeks kematangan, dilakukan pengujian visual (*inferensi*)

secara langsung menggunakan model terbaik terhadap sampel objek buah dengan tingkat kematangan kontras, yaitu buah mentah (*Unripe*) dan buah yang telah matang (*Over-ripe*). Hasil pengujian multi-sampel ini ditampilkan pada Gambar 5.



Gambar 5. Hasil pengujian langsung

Berdasarkan hasil visualisasi pada Gambar 5, sistem terbukti mampu melakukan klasifikasi secara objektif berdasarkan fitur kromatik serta morfologi luar kulit buah. Pada Sampel Uji 1 (buah mentah), model berhasil mengenali dominasi warna hijau pekat secara merata dan mengklasifikasikannya secara tepat sebagai kelas *Unripe* (Kelas 1) dengan tingkat kepercayaan (*Confidence Score*) yang sangat tinggi, yaitu mencapai 97,44%. Sebaliknya, pada Sampel Uji 2 (buah matang), model secara konsisten mendeteksi perubahan pigmen kulit yang telah menggelap dan berhasil memprediksinya sebagai kelas *Ripe First Phase* (Kelas 3) dengan probabilitas keyakinan sebesar 81,53%. Kemampuan inferensi yang kontras dengan tingkat akurasi yang tinggi ini mengonfirmasi ketangguhan model dalam melakukan pemisahan kualitas buah secara otomatis dan non-destruktif.

4.4. Pembahasan

Hasil eksperimen secara keseluruhan membuktikan bahwa model YOLOv8-clc mencapai akurasi sebesar 84,97%. Performa ini sejalan dengan temuan-temuan terbaru dalam bidang *computer vision* pertanian dan konsisten dengan temuan Hananta & Cahyono [21], yang mencatat bahwa YOLOv8 mempertahankan keseimbangan yang superior antara kecepatan dan presisi kategorikal dalam tugas-tugas visual terkait makanan. Lebih lanjut, dengan menyelesaikan transisi yang samar dari fase *Breaking ke Ripe*, penelitian ini mencapai tingkat granularitas yang lebih tinggi dibandingkan dengan model tiga tahap tradisional yang digunakan dalam studi-studi sebelumnya, seperti pada deteksi buah naga [10].

Keputusan untuk menggunakan varian YOLOv8-clc (klasifikasi) alih-alih varian deteksi secara ilmiah dibenarkan oleh sifat tugas itu sendiri. Seperti yang diamati dalam studi pada nanas [18] dan melon [12], model deteksi objek seringkali mengandalkan mAP untuk mengevaluasi akurasi kotak pembatas (*bounding box*). Namun, dalam penilaian (*grading*)

pascapanen di mana keseluruhan buah menjadi subjek utama, metrik kategorikal seperti *F1-Score* dan *Accuracy* lebih representatif untuk performa di dunia nyata. Stabilitas model yang dibuktikan dengan *F1-Score* sebesar 84% menunjukkan ketangguhannya dalam menangani ambiguitas visual yang melekat pada proses pematangan biologis, di mana fitur warna yang tumpang tindih sering menyebabkan kesalahan klasifikasi, seperti yang disebutkan sebelumnya oleh Ahmad et al. [14]. Hal ini membuktikan bahwa klasifikasi 5 tahap berdasarkan *dataset* skala besar (14.710 citra) memberikan solusi otomatis yang andal bagi industri alpukat tanpa kerumitan komputasi regresi koordinat tradisional.

Sebagai bukti visualisasi penerapan model di dunia nyata, hasil inferensi dari sistem klasifikasi ini dapat dilihat pada Gambar 6.



Gambar 6. Contoh hasil inferensi model klasifikasi alpukat hass

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Pelatihan dibatasi hingga 50 epoch karena manajemen sumber daya komputasi, dan citra *dataset* diambil di bawah kondisi pencahayaan yang terkontrol. Akibatnya, performa model di lingkungan alam yang tidak terstruktur atau di bawah intensitas cahaya yang bervariasi masih perlu dieksplorasi lebih lanjut. Selain itu, meskipun akurasi kategorikalnya tinggi, kesalahan klasifikasi pada tahap transisi menunjukkan bahwa fitur warna saja kadang-kadang tidak cukup untuk penilaian kematangan yang mendetail.

Arah penelitian di masa depan harus berfokus pada perpanjangan iterasi pelatihan melebihi 50 *epoch* untuk memungkinkan konvergensi fitur yang lebih dalam. Selain itu, integrasi mekanisme atensi hibrida, seperti *Squeeze-and-Excitation* (SE) atau *Convolutional Block Attention Module* (CBAM), dapat dieksplorasi untuk meningkatkan sensitivitas model terhadap perubahan tekstur dan warna yang samar selama fase *breaking*. Pekerjaan masa depan juga dapat mencakup pengujian model pada *edge devices* untuk mengevaluasi kelayakannya secara *real-time* untuk penyortiran pertanian di lokasi (*on-site*).

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mendemonstrasikan efikasi arsitektur YOLOv8-cls dalam mengklasifikasikan tingkat kematangan alpukat hass ke dalam lima tahap yang mendetail, dengan mencapai akurasi keseluruhan yang tangguh sebesar 84,97%. Dibandingkan dengan model klasifikasi tiga tahap tradisional, penelitian ini memberikan kebaruan yang signifikan dengan mengatasi ambiguitas visual yang tinggi pada fase pematangan transisi serta membuktikan kemampuan generalisasi model yang kuat pada data baru (*unseen data*) dengan latar belakang yang kompleks. Secara praktis, temuan ini menawarkan solusi penyortiran otomatis yang terukur dan objektif untuk rantai pasokan pertanian pascapanen, yang secara signifikan dapat mengurangi subjektivitas manusia dan potensi pemborosan pangan. Mengingat penelitian ini dibatasi oleh durasi pelatihan selama 50 epoch dan pengambilan citra di bawah kondisi pencahayaan yang terkontrol, penelitian selanjutnya disarankan untuk mengeksplorasi perpanjangan iterasi pelatihan dan integrasi mekanisme atensi hibrida guna meningkatkan presisi model selama transisi kolorimetri yang samar. Secara keseluruhan, sistem computer vision otomatis ini membangun landasan yang sangat andal dan teruji secara ilmiah untuk memajukan pertanian presisi dan manajemen kualitas modern.

DAFTAR PUSTAKA

- [1] P. Xavier, P. M. Rodrigues, and C. L. M. Silva, "Shelf-Life Management and Ripening Assessment of 'Hass' Avocado (*Persea americana*) Using Deep Learning Approaches," *Foods*, vol. 13, no. 8, Apr. 2024, doi: 10.3390/foods13081150.
- [2] A. D. Febriani and M. D. Kartikasari, "Detecting Avocado Freshness In Real-Time: A Yolo-Based Deep Learning Approach," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 3, pp. 1485–1502, Jun. 2025, doi: 10.52436/1.jutif.2025.6.3.4626.
- [3] Y. J. Davur, W. Kämper, K. Khoshelham, S. J. Trueman, and S. H. Bai, "Estimating the Ripeness of Hass Avocado Fruit Using Deep Learning with Hyperspectral Imaging," *Horticulturae*, vol. 9, no. 5, May 2023, doi: 10.3390/horticulturae9050599.
- [4] M. F. Bayu and S. Pertiwi, "Estimating the ripeness level of avocado (*Persea americana*) by using ultraviolet reflection," in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics, 2022. doi: 10.1088/1755-1315/1038/1/012049.
- [5] C. Wang, H. Wang, Q. Han, Z. Zhang, D. Kong, and X. Zou, "Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method," *Agriculture (Switzerland)*, vol. 14, no. 5, May 2024, doi: 10.3390/agriculture14050751.

- [6] Y. Dong *et al.*, “GPC-YOLO: An Improved Lightweight YOLOv8n Network for the Detection of Tomato Maturity in Unstructured Natural Environments,” *Sensors*, vol. 25, no. 5, Mar. 2025, doi: 10.3390/s25051502.
- [7] F. A. Siwaka, S. Darmawan Panjaitan, and R. R. Yacoub, “IMPLEMENTASI ALGORITMA DEEP LEARNING YOLOV8 PADA ALAT SORTIR KEMATANGAN BUAH TOMAT,” *Kohesi: Jurnal Multidisiplin Saintek*, Apr. 2025, doi: 10.8734/Kohesi.v1i2.365.
- [8] F. Deng *et al.*, “A new maturity recognition algorithm for Xinhui citrus based on improved YOLOv8,” *Front. Plant Sci.*, vol. 16, 2025, doi: 10.3389/fpls.2025.1472230.
- [9] I. Apeināns, M. Sondors, L. Litavniece, S. Kodors, I. Zarembo, and D. Feldmane, “Cherry Fruitlet Detection using YOLOv5 or YOLOv8?,” in *Vide. Tehnologija. Resursi - Environment, Technology, Resources*, Rezekne Higher Education Institution, 2024, pp. 29–33. doi: 10.17770/etr2024vol2.8013.
- [10] Nurhayati and A. Kusuma, “PERANCANGAN SISTEM DETEKSI KEMATANGAN BUAH NAGA MERAH BERBASIS WEB MENGGUNAKAN METODE ALGORITMA YOLO (YOU ONLY LOOK ONCE),” Jun. 2025. Accessed: Apr. 19, 2026. [Online]. Available: <https://doi.org/10.31932/jutech.v6i1.4990>
- [11] C. Liang, D. Liu, W. Ge, W. Huang, Y. Lan, and Y. Long, “Detection of litchi fruit maturity states based on unmanned aerial vehicle remote sensing and improved YOLOv8 model,” *Front. Plant Sci.*, vol. 16, 2025, doi: 10.3389/fpls.2025.1568237.
- [12] U. Umar, A. Sardjono, H. Kusuma, M. Yani, and H. Widyantara, “Optimizing YOLOv8 for Enhanced Melon Maturity Detection with Attention Mechanisms: A Case Study from Puspalebo Orchard,” May 2025. doi: 10.62527/joiv.9.3.2942.
- [13] D. K. Widyawati *et al.*, “Rock Melon Ripeness Detection Using YOLOv8 and SE-Lightweight YOLOv8,” *Engineering, Technology & Applied Science Research*, vol. 16, no. 2, pp. 33518–33524, Apr. 2026, doi: 10.48084/etasr.16236.
- [14] A. Ahmad, J. Lloret, L. Parra, S. Sendra, and F. Di Gioia, “Comparative Analysis of R-CNN and YOLOv8 Segmentation Features for Tomato Ripening Stage Classification and Quality Estimation,” *Horticulturae*, vol. 12, no. 2, Feb. 2026, doi: 10.3390/horticulturae12020127.
- [15] S. Nuanmeesri, “Enhanced hybrid attention deep learning for avocado ripeness classification on resource constrained devices,” *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-87173-7.
- [16] P. Xavier, P. Rodrigues, and C. L. M. Silva, “‘Hass’ Avocado Ripening Photographic Dataset,” Mendeley Data.
- [17] R. Erz Saragih, A. Rezki Purnajaya, I. Syafrinal, and Y. Pernando, “Mango and Banana Ripeness Detection based on Lightweight YOLOv8,” Sep. 2024. Accessed: Apr. 16, 2026. [Online]. Available: <https://ojs.uajy.ac.id/index.php/jbi/article/view/8895>
- [18] S. A. Prasetya, M. Mihuandayani, Y. Abast, M. Mangole, and J. Rahman, “Implementasi Convolutional Neural Network untuk Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan YOLOv8,” *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 1, pp. 567–575, Jun. 2024, doi: 10.47065/bits.v6i1.5396.
- [19] Z. Jroni, A. Moussaid, and M. Y. Hadi, “Exploring End-to-End object detection with transformers versus YOLOv8 for enhanced citrus fruit detection within trees,” *Systems and Soft Computing*, vol. 6, Dec. 2024, doi: 10.1016/j.sasc.2024.200103.
- [20] P. Kamat, S. Gite, H. Chandekar, L. Dlima, and B. Pradhan, “Multi-class fruit ripeness detection using YOLO and SSD object detection models,” *Discover Applied Sciences*, vol. 7, no. 9, Sep. 2025, doi: 10.1007/s42452-025-07617-7.
- [21] J. K. Hananta and N. Cahyono, “Evaluation of YOLOv8 and Faster R-CNN for Image-Based Food Detection,” 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>