

SISTEM KLASIFIKASI KESEHATAN PEPAYA (*Carica Papaya* L.) MENGGUNAKAN YOLOv11 BERBASIS UNMANNED AERIAL VEHICLE VERTICAL TAKE-OFF LANDING

Health Classification System for Papaya (*Carica papaya* L.) Using YOLOv11 Based on Vertical Take-Off Landing Unmanned Aerial Vehicle

**Fahmi Arsyad¹, Ardan Wiratmoko^{1*}, Mutiara Alifia Ramadhanty¹, Andri Prima
 Nugroho¹, Lilik Sutiarto¹, Takashi Okayasu²**

¹ Smart Agriculture Research Center, Departemen Teknik Pertanian dan Biosistem,
 Fakultas Teknologi Pertanian, Universitas Gadjah Mada, Jln. Flora No. 1 Bulaksumur
 Yogyakarta 55281, Indonesia. fahmi.arsyad2703@mail.ugm.ac.id;
 ardan.w@ugm.ac.id; mutiara.alifia1300@mail.ugm.ac.id; andrew@ugm.ac.id; lilik-
 soetiarso@ugm.ac.id

² Department of Agro-Environmental Science, Faculty of Agriculture, Kyushu
 University, 744 Motooka, Nishi-ku, Fukuoka 810-0395, JAPAN.
 okayasu@bpes.kyushu-u.ac.jp

*) Penulis korespondensi

Diterima 30 April; Disetujui 2 Juni 2026

ABSTRAK

Klasifikasi kesehatan tanaman pepaya (*Carica papaya* L.) merupakan aspek penting dalam mendukung pertanian presisi karena informasi tersebut dapat dimanfaatkan untuk pemantauan kondisi tanaman, estimasi produktivitas, serta pengambilan keputusan manajemen kebun secara tepat. Metode konvensional yang mengandalkan observasi visual masih sering digunakan, tetapi kurang efisien pada skala luas dan berpotensi menimbulkan subjektivitas. Penelitian ini mengembangkan sistem klasifikasi kesehatan tanaman berbasis *computer vision* menggunakan algoritma *deep learning* YOLOv11 yang dilatih dari citra udara beresolusi tinggi hasil akuisisi UAV VTOL. Tahapan penelitian meliputi pengambilan data citra, pembuatan *orthomosaic*, segmentasi *area of interest*, *tiling*, anotasi ke dalam tiga kelas kesehatan yaitu Normal, Moderate, dan Abnormal, serta augmentasi hingga diperoleh 541 citra. Model dilatih selama 100 *epoch* dengan ukuran citra 1024 × 1024 piksel dan dievaluasi menggunakan *precision*, *recall*, *F1-score*, serta *mean Average Precision*. Hasil evaluasi menunjukkan bahwa model mencapai *precision* 0,801, *recall* 0,821, *F1-score* 0,811, dan *mAP50* 0,854 yang mengindikasikan kinerja yang baik. Meskipun demikian, kelas Moderate masih menjadi keterbatasan karena kemiripan karakteristik visual dengan kelas lainnya. Sistem ini mampu menghasilkan visualisasi distribusi spasial kesehatan tanaman yang informatif untuk mendukung implementasi pertanian presisi.

Kata kunci: Citra Udara, Klasifikasi kesehatan tanaman, Pertanian presisi, UAV VTOL, Deteksi objek

ABSTRACT

Papaya plant health classification is an important aspect in supporting precision agriculture, as the information can be utilized for crop monitoring, productivity estimation, and accurate plantation management decision-making. Conventional methods relying on visual observation are still widely used, but they are less efficient at large scales and prone to subjectivity. This study develops a plant health classification

system based on computer vision using the YOLOv11 deep learning algorithm trained on high-resolution aerial imagery acquired from a VTOL UAV. The research stages include image acquisition, orthomosaic generation, area of interest segmentation, tiling, annotation into three health classes (Normal, Moderate, and Abnormal), and data augmentation, resulting in a total of 541 images. The model was trained for 100 epochs with an input size of 1024×1024 pixels and evaluated using precision, recall, F1-score, and mean Average Precision. The evaluation results show that the model achieved a precision of 0.801, recall of 0.821, F1-score of 0.811, and mAP50 of 0.854, indicating good performance. However, the Moderate class remains a limitation due to its visual similarity to other classes. The system is capable of generating informative spatial distribution visualizations of plant health to support precision agriculture implementation.

Keywords: aerial imagery, plant health classification, precision agriculture, UAV VTOL, Object detection

PENDAHULUAN

Pepaya (*Carica papaya* L.) merupakan komoditas hortikultura tropis bernilai ekonomi tinggi yang berbuah secara terus-menerus sepanjang tahun, menjadikannya salah satu tanaman unggulan di sektor pertanian Indonesia (Daszkiewicz, 2022). Komoditas ini tidak hanya dikonsumsi sebagai buah segar, tetapi juga dimanfaatkan sebagai bahan pangan olahan dan sumber enzim papain yang memiliki nilai industri signifikan (Wiratmoko et al., 2025; Wiratmoko et al., 2026a; Nugroho et al., 2026). Tahun 2024, produksi pepaya Indonesia tercatat mencapai sekitar 1,24 juta ton pada tahun 2023, tetapi distribusinya yang tidak merata antarwilayah dan fluktuasi hasil panen akibat kondisi lingkungan masih menjadi permasalahan yang belum terselesaikan. Produktivitas tanaman pepaya rentan terganggu oleh serangan

penyakit, defisiensi unsur hara, serta variabilitas iklim yang secara langsung berdampak pada penurunan kualitas dan kuantitas hasil panen (Ansari et al., 2023; Wiratmoko et al., 2026a). Pengelolaan kebun yang masih bergantung pada metode konvensional seperti pemantauan visual dan pencatatan manual terbukti tidak efisien, lambat, dan rentan kesalahan ketika diterapkan pada skala perkebunan yang luas (Wiratmoko et al., 2022; Syarovy et al., 2023).

Integrasi teknologi *Computer Vision*, *Unmanned Aerial Vehicle* (UAV), dan *deep learning* mampu menyediakan data tanaman secara cepat, konsisten, dan berskala luas melalui pemanfaatan UAV tipe *Vertical Take-Off and Landing* (VTOL) yang mampu mengakuisisi citra beresolusi tinggi (Wiratmoko et al., 2026b). Citra yang diperoleh kemudian diolah menjadi peta orthomosaic

tergeoreferensi sebagai dasar analisis spasial kondisi kebun secara menyeluruh. Algoritma *deep learning* berbasis *Convolutional Neural Network* (CNN) model YOLO (*You Only Look Once*), telah terbukti baik dalam deteksi dan klasifikasi objek secara real-time karena memadukan kecepatan inferensi dengan akurasi yang kompetitif.

Generasi terbaru YOLOv11 yang dikembangkan oleh Ultralytics menghadirkan peningkatan arsitektur pada tahap *feature extraction* dan optimasi inferensi sehingga mampu menghasilkan akurasi deteksi yang lebih tinggi dengan jumlah parameter yang lebih efisien dibandingkan beberapa generasi sebelumnya, termasuk YOLOv8 pada berbagai skenario deteksi objek (Ultralytics, 2025; Hidayatullah et al., 2025). Berdasarkan hasil benchmark Ultralytics, YOLOv11 mampu meningkatkan nilai *mean Average Precision* (mAP) sekaligus mengurangi kompleksitas model hingga sekitar 22% dibanding YOLOv8 pada varian tertentu, sehingga memberikan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi (Ultralytics, 2025). Selain itu, beberapa studi komparatif menunjukkan bahwa varian YOLOv11, khususnya pada model menengah hingga besar, memiliki

performa deteksi dan segmentasi yang lebih baik dibanding YOLOv8 pada citra kompleks dan objek dengan tingkat oklusi tinggi (Sapkota & Karkee, 2024; Hidayatullah et al., 2025).

Meskipun pemanfaatan UAV dan *deep learning* untuk pemantauan kesehatan tanaman telah berkembang pesat, sebagian besar penelitian masih berfokus pada komoditas seperti padi, gandum, jagung, anggur, apel, tomat, tebu, dan basil, dengan tujuan deteksi penyakit, klasifikasi kondisi tanaman, atau pemetaan lahan pertanian (Hermawan et al., 2023; Maulidiya et al., 2024; Trentin et al., 2024; Chen et al., 2020; Mahmood et al., 2026). Studi berbasis UAV juga lebih banyak dilakukan pada tanaman sereal seperti gandum dan padi menggunakan citra RGB, multispektral, maupun hiperspektral untuk identifikasi penyakit dan stres tanaman secara umum (Tang et al., 2023; Mahmood et al., 2026).

Penelitian secara spesifik mengembangkan sistem klasifikasi kesehatan tanaman pepaya menggunakan citra udara yang diakuisisi oleh UAV tipe VTOL masih sangat terbatas, sehingga menyisakan kesenjangan penelitian pada komoditas hortikultura bernilai ekonomi tinggi seperti pepaya (Maulidiya et al., 2024; Hermawan et al., 2023; Trentin et

al., 2024). Berdasarkan gap penelitian tersebut, penelitian ini bertujuan mengembangkan dan mengevaluasi sistem klasifikasi kesehatan tanaman pepaya berbasis citra udara UAV VTOL menggunakan algoritma YOLOv11 dengan varian YOLOv11x (*extra-large*) yang merupakan varian dengan kapasitas parameter terbesar dalam keluarga model YOLOv11, serta 100 epoch pelatihan. Dataset terdiri atas 541 citra yang diperoleh dari area pertanian seluas sekitar 60 hektar di Desa Sendangsari, Kabupaten Sleman, D.I. Yogyakarta, dengan anotasi ke dalam tiga kelas kesehatan yaitu *Normal*, *Moderate*, dan *Abnormal*. Kinerja model kemudian dievaluasi menggunakan metrik *precision*, *recall*, *F1-score*, dan *mean Average Precision* (mAP).

BAHAN DAN METODE

Penelitian dilaksanakan pada bulan Juni sampai bulan Agustus 2025. Pengumpulan data citra udara dilakukan menggunakan UAV VTOL di lahan pertanian pepaya, Desa Sendangsari, Kecamatan Minggir, Kabupaten Sleman, D. I. Yogyakarta. Selain itu, proses studi literatur, pembuatan model, dan penulisan laporan akhir dilaksanakan di Sub-Lab Desain Smart Agriculture Research Center, Laboratorium Energi Mesin

Pertanian, Departemen Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Gadjah Mada, Yogyakarta.


Bahan yang digunakan dalam penelitian ini meliputi dataset citra udara beresolusi tinggi yang diperoleh dari misi terbang UAV VTOL di atas areal perkebunan pepaya. Setiap individu tanaman dianotasi ke dalam tiga kategori kondisi kesehatan, yaitu *Normal*, *Moderate*, dan *Abnormal*. Penentuan kelas dilakukan berdasarkan karakteristik visual kanopi yang dapat diamati dari citra UAV RGB, meliputi warna kanopi dan ukuran tajuk (*canopy/crown area*), yang diketahui berkaitan dengan kondisi pertumbuhan dan vigor tanaman (Lai et al., 2024).

Tanaman dikategorikan sebagai *Normal* apabila memiliki kanopi yang relatif lebat dengan dominasi warna hijau sehat dan luasan tajuk yang optimal. Kelas *Moderate* diberikan pada tanaman yang menunjukkan penurunan vigor secara visual, ditandai oleh warna hijau yang mulai memudar atau tidak merata serta ukuran kanopi yang lebih kecil dibandingkan tanaman normal. Sementara itu, kelas *Abnormal* mencakup tanaman dengan gejala stres yang jelas, seperti dominasi warna kuning atau kecokelatan, kerapatan tajuk yang rendah, serta luasan

kanopi yang jauh lebih kecil atau tidak berkembang.

Penggunaan parameter warna dan luasan kanopi sebagai indikator kondisi pertumbuhan tanaman telah banyak digunakan dalam pemantauan tanaman berbasis UAV karena berkaitan erat dengan vigor vegetasi, aktivitas fotosintesis, status pertumbuhan tanaman, serta dapat digunakan untuk mengevaluasi

kondisi kesehatan tanaman secara non-destruktif (Lai et al., 2024). Perangkat keras yang digunakan meliputi UAV VTOL Trinity Pro, kamera RGB Sony RX1R Mark II, dan komputer *High Performance Computing* (HPC) dengan GPU NVIDIA GeForce RTX 4090. Perangkat lunak yang digunakan antara lain Python 3.12, *framework deep learning* Ultralytics YOLO versi YOLOv11x.



Gambar 1. Diagram Alir Penelitian

Penelitian dilakukan sebagaimana ditunjukkan pada Gambar 1, yang diawali dari tahap persiapan alat dan bahan,

dilanjutkan dengan pembuatan misi terbang serta pengambilan data menggunakan UAV VTOL untuk

memperoleh citra udara, kemudian diproses melalui pembuatan orthomosaic, segmentasi, penentuan area of interest (AoI), hingga *tiling* citra berukuran 1024×1024 piksel dan sampling area sehingga diperoleh 230 sampel citra. Selanjutnya dilakukan anotasi menggunakan *bounding box* dan pembagian kelas (Normal, Moderate, dan Abnormal), kemudian augmentasi data berupa rotasi 90° , 180° , 270° , serta *flipping* horizontal dan vertikal sehingga jumlah dataset meningkat menjadi 541 citra. Dataset tersebut dibagi menjadi 471 citra *training*, 46 citra *validation*, dan 24 citra *testing*, kemudian digunakan untuk pelatihan model YOLOv11x (*extra-large*), yaitu varian terbesar dari arsitektur YOLO generasi ke-11 yang dikembangkan oleh Ultralytics. Pelatihan dilakukan menggunakan *AutoOptimizer* bawaan Ultralytics yang secara otomatis memilih algoritma optimasi terbaik berdasarkan konfigurasi model, dengan variasi hyperparameter berupa *epoch* (50, 100, dan 150), *batch size* 8, *learning rate* sebesar 0,00001, serta ukuran input citra 1024×1024 piksel. Selanjutnya dilakukan validasi dan evaluasi menggunakan *confusion matrix normalized* serta metrik *precision*, *recall*, *mean Average Precision* pada *threshold Intersection over Union* (IoU) 0,50

(mAP50), dan mAP pada rentang *threshold* IoU 0,50–0,95 (mAP50–95).

Precision adalah metrik yang digunakan untuk mengukur ketepatan model dalam membuat prediksi positif. Persamaan *precision* ditunjukkan pada persamaan berikut.

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

Recall adalah metrik untuk menilai kemampuan model menemukan seluruh data yang benar-benar termasuk kelas positif. Persamaan *recall* ditunjukkan pada Persamaan 2.

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

Mean Average Precision (mAP) adalah metrik yang digunakan untuk menilai performa keseluruhan model dalam mendeteksi objek dari berbagai kelas. Persamaan mAP ditunjukkan pada Persamaan 3.

$$mAP = \frac{1}{c} \sum_{i=1}^c AP_i \quad (3)$$

F1-score adalah metrik evaluasi yang digunakan untuk mengukur keseimbangan antara *precision* dan *recall*. Persamaan dari F1-score ditunjukkan pada Persamaan 4.

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


HASIL DAN PEMBAHASAN

Karakteristik Dataset

Dataset diperoleh dari akuisisi citra udara di lahan pertanian pepaya yang berlokasi di Desa Sendangsari, Kecamatan Minggir, Kabupaten Sleman, Daerah Istimewa Yogyakarta.

Akuisisi citra udara ini dilakukan untuk memperoleh data spasial yang representatif terhadap kondisi aktual tanaman di lapangan. Pengambilan citra dilakukan menggunakan UAV tipe *Vertical Take-Off and Landing* (VTOL) yang dilengkapi kamera resolusi tinggi,

dengan ketinggian terbang sekitar 120 meter. Citra hasil akuisisi yang berjumlah sekitar ± 900 gambar diproses menggunakan pendekatan fotogrametri untuk menghasilkan *orthomosaic*, yaitu citra gabungan yang merepresentasikan kondisi lahan secara utuh dan kontinu. Proses ini bertujuan untuk mengoreksi distorsi geometrik serta menyusun citra menjadi satu kesatuan spasial yang lebih mudah dianalisis. Hasil *orthomosaic* digunakan sebagai dasar utama dalam proses pengolahan data, sebagaimana ditunjukkan pada Gambar 2 (a).



Gambar 2. (a) Hasil *Orthomosaic* dari Citra UAV VTOL, (b) Lahan 1, (c) Lahan 2, (d) Lahan 3

Berdasarkan hasil *orthomosaic*, dilakukan segmentasi sesuai *area of interest* (AoI) yang ditunjukkan pada

Gambar 2 (b), (c), (d). AoI berfokus pada area budidaya pepaya sehingga dataset yang dihasilkan sesuai dengan kebutuhan

analisis deteksi dan klasifikasi. Segmentasi ini membantu membatasi area analisis agar lebih sesuai serta mengurangi *noise* dari objek lain di luar lahan pepaya (Zhang et al., 2021).


Citra pada area AoI dipotong menjadi *tile* berukuran seragam 1024×1024 piksel untuk mempermudah proses anotasi dan pelatihan model. Dataset hasil *tiling* kemudian dianotasi secara manual menggunakan *bounding box* dengan tiga kelas kesehatan tanaman, yaitu Normal, Moderate, dan Abnormal (Muhammad et al., 2021). Dari 230 citra awal, jumlah data ditingkatkan menjadi 541 citra melalui augmentasi berupa rotasi 90° , 180° , dan 270° , serta flipping horizontal dan vertikal untuk memperkaya variasi sudut pandang dan bentuk kanopi (Wang et al., 2020). Selanjutnya, dataset dibagi menjadi data pelatihan, validasi, dan pengujian untuk mendukung pengembangan model klasifikasi berbasis YOLOv11.

Sebanyak 541 citra yang telah disiapkan kemudian dibagi menjadi 471 citra *training* (87,1%), 46 citra *validation* (8,5%), dan 24 citra *testing* (4,4%). Pembagian data dilakukan dengan rasio

mendekati 90% : 10%, di mana porsi terbesar dialokasikan untuk training agar model dapat mempelajari pola data secara maksimal (Milani, 2021). Data *validation* digunakan untuk memantau performa model selama proses pelatihan, sedangkan data *testing* digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah digunakan sebelumnya.

Model YOLO11x dalam Klasifikasi Kesehatan Pepaya

Model YOLOv11 dievaluasi berdasarkan hasil pelatihan menggunakan konfigurasi *epoch* 100 dengan mengacu pada matriks evaluasi serta *confusion matrix*. Evaluasi ini bertujuan untuk mengidentifikasi kemampuan model dalam membedakan tiga kelas kesehatan tanaman pepaya, yaitu Normal, Moderate, dan Abnormal. Distribusi objek pada dataset relatif seimbang dengan jumlah 881 objek Normal (33,26%), 887 objek Moderate (33,48%), dan 881 objek Abnormal (33,26%), sehingga performa model dapat dievaluasi secara lebih objektif tanpa dominasi salah satu kelas.



Gambar 3. *Confusion Matrix Normalized*

Seperti ditunjukkan pada Gambar 3, *confusion matrix Normalized* yang telah dinormalisasi memperlihatkan distribusi prediksi model pada setiap kelas dengan cukup jelas. Model menunjukkan kinerja terbaik pada kelas Normal dengan nilai *true positive rate* sebesar 90%. Hal ini menandakan bahwa model mampu mengenali tanaman pepaya dalam kondisi sehat dengan baik. Kemampuan tersebut dipengaruhi oleh karakteristik visual tanaman sehat yang cenderung konsisten, seperti warna kanopi yang merata, tekstur daun yang jelas, serta bentuk daun yang teratur (Ehiem et al., 2019). Pada kelas Moderate dan Abnormal, nilai TPR masing-masing mencapai sekitar 77% dan 74%. Meskipun lebih rendah dibandingkan kelas Normal, nilai ini

masih tergolong cukup baik untuk aplikasi pertanian presisi di lingkungan lapangan yang memiliki variasi kondisi pencahayaan.

Kelas *Moderate* menjadi kelas yang paling sulit diprediksi oleh model. Hal ini terlihat dari tingginya kesalahan klasifikasi ke kelas lain, terutama ke kelas *Abnormal* sebesar 23% dan ke kelas *Normal* sebesar 10%. Selain itu, kelas *Abnormal* juga mengalami kesalahan klasifikasi ke kelas *Moderate* sebesar 15%. Ambiguitas tersebut berkaitan dengan miripnya karakteristik visual antara kelas *Moderate* dan *Abnormal*. Karena perubahan kondisi kesehatan tanaman berlangsung secara bertahap, sebagian tanaman pada kelas *Moderate* memiliki karakteristik visual yang mendekati kelas


Abnormal, sehingga batas antar kelas menjadi kurang tegas dan lebih sulit dibedakan oleh model (Ferentinos, 2018). Fenomena ini umum terjadi pada klasifikasi kesehatan tanaman berbasis citra, terutama ketika perbedaan antar kelas ditentukan oleh perubahan warna dan struktur kanopi yang bersifat kontinu (Barbedo, 2018).

Permasalahan lain yang cukup signifikan adalah tingginya kesalahan klasifikasi kelas *Moderate* ke kategori *Background*, yaitu sebesar 50%. Selain itu, pada kelas *Abnormal* juga ditemukan kesalahan ke *Background* sebesar 34%, sedangkan pada kelas *Normal* sebesar 16%. Hal ini menunjukkan bahwa sebagian data tanaman tidak terdeteksi sebagai objek, melainkan dianggap sebagai latar belakang. Kondisi ini kemungkinan disebabkan oleh kualitas citra yang kurang optimal, seperti pencahayaan yang tidak merata, keberadaan bayangan, atau dominasi area tanah pada gambar (Zhang et al., 2021). Dampaknya, nilai *recall* terutama pada kelas *Moderate* menjadi rendah karena banyak data yang tidak berhasil dikenali oleh model.

Pada kelas *Normal*, kesalahan klasifikasi relatif lebih kecil, yaitu sebesar

6% yang terdeteksi sebagai *Moderate* dan 16% sebagai *Background*. Hal ini menunjukkan bahwa sebagian kecil tanaman sehat masih salah dikenali sebagai tanaman yang mengalami gangguan atau bahkan tidak terdeteksi sebagai objek. Sementara itu, kesalahan dari kelas *Background* ke kelas tanaman tergolong sangat rendah, yaitu hanya sekitar 2-3%, sehingga dapat disimpulkan bahwa model cukup baik dalam membedakan objek tanaman dan latar belakang. Selanjutnya, hasil metrik evaluasi ditunjukkan pada Gambar 4.

Berdasarkan hasil evaluasi yang ditunjukkan pada Gambar 4, model yang dilatih dengan 100 *epoch* dan *learning rate* 0,00001 menunjukkan kinerja yang baik. Pada *training loss*, nilai *box loss* menurun dari sekitar 1,6 hingga mendekati 0,9, yang menunjukkan bahwa model semakin akurat dalam memprediksi *bounding box*. Penurunan juga terjadi pada *classification loss* dari 2,0 menjadi sekitar 0,5, serta pada *dfl loss* dari 1,7 menjadi sekitar 1,3, meskipun penurunannya lebih lambat dibandingkan komponen lainnya. Hal ini menunjukkan bahwa kemampuan model dalam membedakan kelas dan memisahkan objek dari latar belakang semakin meningkat.



Gambar 4. Matriks Evaluasi (a) *train box loss*, (b) *train classification loss*, (c) *train distribution focal loss*, (d) *metrics precision*, (e) *metrics recall*, (f) *validation box loss*, (g) *validation classification loss*, (h) *metrics mAP50*, (i) *metrics mAP50-95*

Tabel 1. Kinerja Model dalam Melakukan Deteksi Objek

<i>Epoch</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP50</i>	<i>mAP50-95</i>	<i>F1-score</i>
100	0.801	0.821	0.854	0.549	0.811

Pada *validation loss*, ketiga komponen (*box loss*, *cls loss*, dan *dfl loss*) mengalami penurunan yang cukup cepat di awal pelatihan, kemudian stabil sekitar nilai 1,0 dengan fluktuasi yang kecil. Kondisi ini menunjukkan bahwa model tidak mengalami *overfitting* dan memiliki proses pembelajaran yang stabil. Dari sisi metrik performa, nilai *precision* meningkat hingga sekitar 0,82, yang berarti kesalahan *false positive* dapat dikurangi. Nilai *recall* juga berada di kisaran 0,82, yang menunjukkan

kemampuan model dalam mengurangi *false negative* sudah cukup baik (Milani et al., 2021). Selain itu, nilai *mAP50* mencapai lebih dari 0,8, menandakan kemampuan deteksi yang baik pada ambang IoU 0,5, sedangkan *mAP50-95* berada di kisaran 0,55 yang menunjukkan performa deteksi yang cukup baik pada berbagai tingkat IoU.

Berdasarkan tabel 1 kinerja deteksi objek, model YOLO11x yang dilatih selama 100 *epoch* menunjukkan performa yang cukup seimbang pada seluruh metrik

evaluasi. Nilai *precision* sebesar 0,801 mengindikasikan bahwa sebagian besar prediksi objek yang dihasilkan model tergolong tepat, sementara nilai *recall* sebesar 0,821 menunjukkan kemampuan model dalam mendeteksi objek yang benar sudah cukup tinggi. Keseimbangan antara *precision* dan *recall* ini ditunjukkan pada nilai *F1-score* sebesar 0,811 yang menjadi indikator bahwa model memiliki performa klasifikasi yang stabil dan tidak terlalu bias ke salah satu metrik. Selain itu, nilai *mAP50* sebesar 0,854 menunjukkan bahwa model mampu melakukan deteksi objek dengan tingkat akurasi yang baik pada *threshold* IoU 0,5. Sementara itu, nilai *mAP50-95* sebesar 0,549 yang lebih rendah mengindikasikan bahwa performa model menurun pada *threshold* IoU yang lebih rapat.


Implementasi Model Klasifikasi Kesehatan Pepaya

Implementasi dilakukan untuk mengevaluasi kemampuan model dalam mendeteksi dan mengklasifikasikan kondisi tanaman pada skala kebun secara spasial. Proses ini mencakup penerapan model pada *orthomosaic* yang telah melalui tahap *segmentasi* AoI. Hasil yang diperoleh divisualisasikan dalam bentuk pemetaan titik terklasifikasi untuk

mempermudah analisis distribusi kondisi tanaman di lapangan.

Hasil implementasi sistem deteksi dan penghitungan otomatis tanaman pepaya pada Gambar 5 menunjukkan representasi distribusi spasial tanaman dalam bentuk grid titik yang terklasifikasi. Setiap titik berwarna merepresentasikan hasil prediksi model terhadap kondisi tanaman, di mana warna hijau mengindikasikan tanaman dalam kondisi normal, biru menunjukkan kondisi moderate, dan merah menandakan tanaman abnormal.

Pola sebaran warna pada area kebun terlihat tidak homogen, dengan beberapa bagian didominasi oleh warna hijau yang menandakan kondisi tanaman relatif baik, sementara area lain memperlihatkan akumulasi titik biru dan merah yang mengindikasikan adanya potensi stres tanaman atau gangguan kesehatan. Visualisasi ini memberikan kemudahan dalam mengidentifikasi zona-zona tertentu yang memerlukan perhatian lebih, terutama pada bagian tengah hingga sisi tertentu yang menunjukkan kepadatan titik abnormal lebih tinggi. Representasi berbasis grid ini juga membantu dalam melihat kerapatan tanaman sekaligus konsistensi deteksi yang dihasilkan oleh model.



Gambar 5. Hasil Implementasi Sistem Klasifikasi Kesehatan Pepaya

Implementasi dilakukan menggunakan *orthomosaic* yang berbeda dari data pelatihan, sehingga mampu merepresentasikan performa model dalam kondisi yang lebih realistis di lapangan. Sebelum proses deteksi, dilakukan segmentasi area berdasarkan AoI untuk memastikan bahwa analisis hanya terfokus pada wilayah yang mengandung tanaman pepaya dan mengurangi interferensi dari objek non-relevan. Tahapan ini berdampak pada efisiensi komputasi sekaligus meningkatkan akurasi spasial hasil deteksi. Distribusi warna yang terlihat berbeda juga mencerminkan kemampuan model dalam menangkap perbedaan kondisi tanaman akibat faktor lingkungan seperti pencahayaan, variasi sudut pengambilan citra, dan heterogenitas kondisi lahan. Penggunaan data dari misi

penerbangan yang berbeda memperlihatkan bahwa sistem tetap mampu menghasilkan pola deteksi yang konsisten meskipun terdapat perubahan kondisi akuisisi data, termasuk perbedaan intensitas cahaya dan kualitas citra udara.

KESIMPULAN DAN SARAN

Kesimpulan penelitian ini menunjukkan bahwa model YOLO11x berbasis citra UAV VTOL mampu mengklasifikasikan kesehatan tanaman pepaya dengan kinerja yang baik, ditunjukkan oleh nilai *precision* 0,801, *recall* 0,821, *F1-score* 0,811, dan *mAP50* sebesar 0,854, sehingga tujuan penelitian untuk menghasilkan sistem klasifikasi yang akurat dan aplikatif pada skala kebun dapat tercapai. Model memiliki performa terbaik pada kelas Normal, namun masih

terdapat kesalahan klasifikasi pada kelas Moderate dan Abnormal akibat kemiripan karakteristik visual serta pengaruh kondisi citra lapangan. Implementasi pada *orthomosaic* juga mampu menampilkan distribusi spasial kondisi tanaman secara informatif untuk mendukung pertanian presisi. Saran untuk penelitian selanjutnya adalah meningkatkan jumlah dan kualitas dataset terutama pada kelas Moderate dan Abnormal, memanfaatkan data multispektral untuk meningkatkan sensitivitas deteksi.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi dan terima kasih kepada Working Group Food Security (WGFS 1.2) Precision Agriculture and Smart Farming, Pusat Unggulan Antar Perguruan Tinggi (PUAPT) Universitas Gadjah Mada atas dukungan fasilitas penelitian. Penulis juga mengucapkan terima kasih kepada Smart Agriculture Research Center, Departemen Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Gadjah Mada atas dukungan teknis, kolaborasi riset, pendampingan ilmiah, serta lingkungan akademik yang mendukung pelaksanaan penelitian ini.

DAFTAR PUSTAKA

Ansari, A., Pranesti, A., Telaumbanua, M., Alam, T., Taryono, Wulandari, R.

A., Nugroho, B. D. A., & Supriyanta. (2023). Evaluating the effect of climate change on rice production in Indonesia using multimodelling approach. In *Heliyon* (Vol. 9, Number 9). Elsevier Ltd. <https://doi.org/10.1016/j.heliyon.2023.e19639>

Barbedo, J. G. A. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172, 84–91. <https://doi.org/10.1016/j.biosystemseng.2018.05.013>

Chen, J., Chen, J., Zhang, D., Sun, Y., & Nanekharan, Y. A. (2020). Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture*, 173, 105393. <https://doi.org/10.1016/j.compag.2020.105393>

Daszkiewicz, T. (2022). Food Production in the Context of Global Developmental Challenges. *Agriculture (Switzerland)*, 12(6). <https://doi.org/10.3390/agriculture12060832>

Ehiem, J. C., Ndirika, V. I. O., Onwuka, U. N., Gariepy, Y., & Raghavan, V. (2019). Water absorption characteristics of *Canarium Schweinfurthii* fruits. *Information Processing in Agriculture*, 6(3), 386–395. <https://doi.org/10.1016/j.inpa.2018.12.002>

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>

Hermawan, E., Agustian, S., & Saputra, D. M. (2023). KLASIFIKASI

- KESEHATAN PADA TANAMAN PADI MENGGUNAKAN CITRA UNMANED AERIAL VEHICLE (UAV) DENGAN METODE CONVOLUTIONAL NEURAL NETWORKS (CNN). *Jurnal Ilmiah Teknologi Informasi Terapan*, 9, 308–318.
- Hidayatullah, P., Syakrani, N., Sholahuddin, M. R., Gelar, T., & Tubagus, R. (2026). YOLOv8 to YOLO11 Performance Benchmark and Comprehensive Architectural Comparative Review. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 10(2), 341–354. <https://doi.org/10.29207/resti.v10i2.6598>
- Lai, S., Ming, H., Huang, Q., Qin, Z., Duan, L., Cheng, F., & Han, G. (2024). Remote Sensing Extraction of Crown Planar Area and Plant Number of Papayas Using UAV Images with Very High Spatial Resolution. *Agronomy*, 14(3), 636. <https://doi.org/10.3390/agronomy14030636>
- Mahmood, A., Anwar, W., Sattar, H., Hassan, S. R., Sheraz, M., & Chuah, T. C. (2025). Deep learning framework using UAV imagery for multi-disease detection in cereal crops. *Scientific Reports*, 16(1), 3339. <https://doi.org/10.1038/s41598-025-33304-z>
- Maulidiya, E., Fatichah, C., Suciati, N., & Baskoro, F. (2024). UAV LAND COVER CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK FEATURE MAP WITH A COMBINATION OF MACHINE LEARNING. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 45–55. <https://doi.org/10.12962/j24068535.v22i1.a1214>
- Milani, S. (2021). A distributed source autoencoder of local visual descriptors for 3D reconstruction. *Pattern Recognition Letters*, 146, 193–199. <https://doi.org/10.1016/j.patrec.2021.03.019>
- Muhammad, G., Alshehri, F., Karray, F., Saddik, A. El, Alsulaiman, M., & Falk, T. H. (2021). A comprehensive survey on multimodal medical signals fusion for smart healthcare systems. *Information Fusion*, 76, 355–375. <https://doi.org/10.1016/j.inffus.2021.06.007>
- Nugroho, A. P., Wiratmoko, A., Oktasari, U. D., Kusumawardani, R. F., Pradana, F. A., Sutiarso, L., Sukarman, Suwardi, Primananda, S., & Okayasu, T. (2026). A confidence-weighted decision framework for on-site fertilizer quality screening and off-spec detection in smart agricultural systems using low-cost macronutrient sensors. *Smart Agricultural Technology*, 14, 102103. <https://doi.org/10.1016/j.atech.2026.102103>
- Ramadhanty, M. A., Wiratmoko, A., Arsyad, F., Nugroho, A. P., Sutiarso, L., & Okayasu, T. (2026). Analisis Hubungan Nilai SPAD dan Indeks Vegetasi Berbasis Citra Multispektral Unmanned Aerial Vehicle Vertical Take-Off and Landing (UAV-VTOL) pada Tanaman Pepaya. *Jurnal Pertanian Presisi (Journal of Precision Agriculture)*, 10(1), 48–64. <https://doi.org/10.35760/jpp.2026.v10i1.261>
- Sapkota, R., & Karkee, M. (2025). Comparing YOLOv11 and YOLOv8 for instance segmentation of occluded and non-occluded

- immature green fruits in complex orchard environment*. <http://arxiv.org/abs/2410.19869>
- Syarovy, M., Nugroho, A. P., Sutiarto, L., Suwardi, Muna, M. S., Wiratmoko, A., Sukarman, & Primananda, S. (2023). Utilization of big data in oil palm plantation to predict production using Artificial Neural Network model. In Proceedings of the International Conference on Sustainable Environment, Agriculture and Tourism (ICOSEAT 2022), Advances in Biological Sciences Research, 26, 492–502. Atlantis Press. https://doi.org/10.2991/978-94-6463-086-2_67
- Trentin, C., Ampatzidis, Y., Lacerda, C., & Shiratsuchi, L. (2024). Tree crop yield estimation and prediction using remote sensing and machine learning: A systematic review. In *Smart Agricultural Technology* (Vol. 9). Elsevier B.V. <https://doi.org/10.1016/j.atech.2024.100556>
- Ultralytics. (2025). *YOLO11 vs YOLOv8: A Comprehensive Technical Comparison of Real-Time Vision Models*. Ultralytics Docs. <https://docs.ultralytics.com/compare/yolo11-vs-yolov8/>
- Wang, C., Hao, C., & Guan, X. (2020). Hierarchical and overlapping social circle identification in ego networks based on link clustering. *Neurocomputing*, 381, 322–335. <https://doi.org/10.1016/j.neucom.2019.11.080>
- Wiratmoko, A., Nugroho, A. P., Afif, S., Arsyad, F., Ramadhanty, M. A., & Sutiarto, L. (2025). Analisis Dinamika Vapor Pressure Deficit pada Lingkungan Mikroklimat Padi Sawah Terbuka Berbasis Smart Automatic Weather Station Tipe Ultrasonik. *Journal of Agricultural and Biosystem Engineering Research*, 6(2), 118. <https://doi.org/10.20884/1.jaber.2025.6.2.19697>
- Wiratmoko, A., Nugroho, A. P., Manik, K. E., Pradana, F. A., Sutiarto, L., & Okayasu, T. (2026a). Multidepth soil sensing with an embedded hydrothermal stress index captures stratified stability in hardpan-limited tropical Spodosol oil palm systems. *Computers and Electronics in Agriculture*, 251, 112026. <https://doi.org/10.1016/j.compag.2026.112026>
- Wiratmoko, A., Nugroho, A. P., Muna, M. S., Syarovy, M., Suwardi, Sukarman, & Sutiarto, L. (2022). *Development of Cloud-Based Decision Support System for Fertilizer Management - A Case Study in Wilmar Oil Palm Plantation*. https://doi.org/10.2991/978-94-6463-086-2_69
- Wiratmoko, A., Nugroho, A. P., Ramadhanty, M. A., Arsyad, F., Pradana, F. A., Pamungkas, B. S., Sutiarto, L., & Okayasu, T. (2026b). Predicting physiological health states of tropical papaya using UAV multispectral imagery for precision agriculture monitoring. *Agricultural Environment and Sustainability*, 1(3), 100023. <https://doi.org/10.1016/j.ages.2026.100023>
- Zhang, H., Du, H., Zhang, C., & Zhang, L. (2021). An automated early-season method to map winter wheat using time-series Sentinel-2 data: A case study of Shandong, China. *Computers and Electronics in Agriculture*, 182, 105962. <https://doi.org/10.1016/j.compag.2020.105962>