



EVALUASI KINERJA MODEL YOLOv11 UNTUK KLASIFIKASI TINGKAT KEMANISAN BUAH NANAS

Willy Muhammad Fauzi¹, Dwi Vernanda², Tri Herdiawan Apandi³

^{1,2,3} Politeknik Negeri Subang, Blok Kaleng Banteng, Desa Cibogo, Kec. Cibogo, Kabupaten Subang, Jawa Barat 41285

* Email Korespondensi: willy.fauzi@polsub.ac.id

INFO ARTIKEL


Sejarah Artikel:

Diterima Tgl. 23/07/2026

Diperbaiki Tgl. 29/07/2026

Disetujui Tgl. 30/07/2026

Tersedia daring Tgl. 30/07/2026



e-ISSN 2961-9009
p-ISSN 2963-1289

DOI:

<https://doi.org/10.64626/jukomtek.v5i2.734>

Abstract: Sweetness is a primary determinant of pineapple quality, yet its conventional measurement requires cutting the fruit open and is therefore unsuitable for large-scale, non-destructive sorting. Existing image-based studies on pineapple sweetness generally treat the task as whole-image classification on pre-isolated fruit and report aggregate accuracy, leaving unclear how a model that must localize and classify simultaneously behaves at category boundaries. This study aims to measure and diagnose the performance limits of a single-view YOLOv11 detector in classifying pineapples into three sweetness categories, namely Asam (sour), Manis Ideal (ideal) and Sangat Manis (very sweet). A dataset of 4,475 annotated instances was trained for 50 epochs and evaluated using precision, recall, mean average precision, a confusion matrix, and confidence-threshold sensitivity curves. The model reached an overall mean average precision of 0.555 at an intersection-over-union threshold of 0.5, with a peak F1-score of 0.58; per class, Asam was the most reliable (0.695) while Manis Ideal (0.505) and Sangat Manis (0.465) lagged behind. At the default threshold only 32 to 64 percent of instances per class were classified correctly, far below the recall range observed on the training curves. The novelty of this work lies in the diagnostic characterisation of that gap: errors concentrate almost symmetrically between visually adjacent categories, not between the extremes, and reported recall substantially overstates behaviour at a real operating threshold. A single viewpoint without class-imbalance handling therefore cannot reliably separate boundary categories, which gives the empirical basis for the multi-view refinement pursued next.

Keywords:

Pineapple, YOLOv11, Object detection, Sweetness classification, Class imbalance

Abstrak: Tingkat kemanisan merupakan penentu utama kualitas buah nanas, namun pengukuran konvensional mengharuskan buah dibelah sehingga tidak praktis untuk penyortiran skala besar. Studi berbasis citra pada kemanisan nanas umumnya merumuskan persoalan ini sebagai klasifikasi citra utuh pada buah yang sudah terisolasi dan melaporkan akurasi agregat, sehingga belum diketahui bagaimana perilaku model yang harus melokalisasi sekaligus mengklasifikasi pada batas antar kategori kemanisan yang berdekatan. Penelitian ini bertujuan mengukur dan mendiagnosis batas kinerja detektor YOLOv11 satu sudut pandang dalam mengklasifikasikan nanas ke dalam tiga kategori kemanisan, yaitu Asam, Manis Ideal, dan Sangat Manis, dari satu citra per buah. Dataset berisi 4.475 instance beranotasi dilatih selama 50 epoch dan dievaluasi menggunakan precision, recall, mean average precision, confusion matrix, serta kurva sensitivitas ambang kepercayaan.

	Model mencapai mean average precision keseluruhan 0,555 pada ambang irisan 0,5, dengan F1-score puncak 0,58; secara per kelas, Asam paling andal (0,695) sementara Manis Ideal (0,505) dan Sangat Manis (0,465) tertinggal. Pada ambang bawaan, hanya 32 sampai 64 persen instance per kelas yang terklasifikasi benar, jauh di bawah rentang recall pada kurva pelatihan. Kebaruan penelitian ini terletak pada karakterisasi diagnostik atas kesenjangan tersebut: kesalahan terkonsentrasi hampir simetris antar kategori yang berdekatan secara visual dan bukan antar dua kelas ekstrem, serta recall yang dilaporkan jauh lebih optimistis dibanding perilaku model pada ambang operasi sebenarnya. Disimpulkan bahwa satu sudut pandang tanpa penanganan ketidakseimbangan kelas belum cukup memisahkan kategori kemanisan yang terbatas, dan hal ini menjadi dasar empiris bagi penyempurnaan berbasis multi-sudut pandang berikutnya. Kata Kunci: Nanas, YOLOv11, Deteksi objek, Klasifikasi kemanisan, Ketidakseimbangan kelas
	©2026. Diterbitkan oleh Jurnal Komputer dan Teknologi (JUKOMTEK). Artikel ini memiliki akses terbuka di bawah lisensi CC BY (https://creativecommons.org/licenses/by/4.0/)

PENDAHULUAN

Kabupaten Subang merupakan salah satu sentra produksi nanas terbesar di Jawa Barat (Badan Pusat Statistik (BPS) Kabupaten Subang, 2024), tingkat kemanisan nanas yang umum dinyatakan sebagai rasio TSS/TA menjadi indikator penting untuk penyortiran mutu dan penerimaan pasar karena rasio gula dan asam berkontribusi langsung pada flavor, kematangan komersial dan kualitas nanas (Paull et al., 2020; R. et al., 2021; VIANA et al., 2020). Penyortiran manual berdasarkan warna kulit dan aroma masih banyak dilakukan, namun pendekatan berbasis inspeksi manusia cenderung subjektif dan tidak konsisten (G et al., 2024; Maimunah Mohd Ali et al., 2020). Pengukuran rasio TSS/TA dengan refraktometer dan titrasi memang lebih akurat, tetapi bersifat destruktif dan kurang praktis untuk penilaian setiap buah dalam satu batch karena pengukuran gula dan asam lazimnya memerlukan ekstraksi sari buah, refraktometri dan titrasi yang lambat untuk aplikasi lapangan (Sangsongfa et al., 2020). Karena itu, teknologi non-destruktif semakin menarik untuk evaluasi mutu nanas, termasuk computer vision dan image processing (Mohd Ali et al., 2023). Dalam konteks ini, computer vision menawarkan alternatif non-destruktif dengan memanfaatkan ciri visual eksternal buah untuk mendeteksi kelas tertentu. (Maimunah Mohd Ali et al., 2020).

Sebagian besar pendekatan computer vision untuk penilaian mutu buah nanas masih bertumpu pada citra satu sudut pandang, karena pendekatan ini sederhana untuk diimplementasikan dan tetap dapat mencapai kinerja yang baik pada tugas grading tertentu (Goyal et al., 2023;

Kanjanawattana et al., 2023). Pada buah nanas, pendekatan berbasis citra telah dinyatakan efektif untuk berbagai tugas seperti klasifikasi kematangan, sweetness/taste recognition, grading dan deteksi mahkota, sehingga mendukung kelayakan penggunaan informasi visual eksternal sebagai proksi mutu (Siricharoen et al., 2023; Wan Nurazwin Syazwani et al., 2022). Namun, untuk klasifikasi kemanisan, hubungan antara tampilan visual dan rasa tidak selalu kuat atau linear, warna kulit saja dapat menyesatkan, dan rasa/aroma dipengaruhi kombinasi banyak variabel fisikokimia selama pematangan.

Meskipun demikian, telaah kritis terhadap penelitian terdahulu memperlihatkan sejumlah keterbatasan yang belum terjawab. Pertama, sebagian besar studi klasifikasi kemanisan nanas berbasis citra memformulasikan persoalan ini sebagai klasifikasi citra utuh pada buah yang sudah terisolasi dari latar belakangnya (Kanjanawattana et al., 2023; Sangsongfa et al., 2020), sehingga tahap lokalisasi diasumsikan telah selesai dan hasilnya sulit dipindahkan langsung ke kondisi lini sortasi yang menuntut lokalisasi dan klasifikasi berjalan bersamaan. Kedua, kinerja umumnya dilaporkan dalam bentuk akurasi atau F1 agregat, sementara struktur kesalahan antar kelas jarang diuraikan; padahal kategori kemanisan pada dasarnya merupakan diskretisasi dari skala TSS/TA yang kontinu, sehingga pasangan kelas yang bertetangga secara alami lebih rawan tertukar dibanding pasangan kelas yang berjauhan. Ketiga, distribusi jumlah sampel antar kategori kemanisan jarang dilaporkan maupun ditangani secara eksplisit, meskipun ketidakseimbangan kelas diketahui menurunkan kinerja model pada kelas minoritas (Johnson & Khoshgoftaar, 2019; Miftahushudur et al., 2025). Keempat, metrik yang dilaporkan lazimnya diambil pada titik operasi terbaik tanpa membahas sensitivitasnya terhadap ambang kepercayaan, padahal pada penerapan nyata ambang tersebut harus ditetapkan di muka. Sebagai pembandingan, pendekatan non-destruktif berbasis spektroskopi seperti VIS/NIR dan NIR-HSI menawarkan akurasi penilaian mutu internal yang lebih tinggi (Qiu et al., 2023), tetapi kebutuhan instrumen khusus membuatnya kurang terjangkau bagi sentra produksi rakyat, sehingga pendekatan berbasis kamera RGB tetap relevan untuk dipetakan batas kemampuannya.

Keterbatasan ini diperkirakan lebih menonjol pada skenario satu sudut pandang, karena model hanya melihat sebagian informasi permukaan buah. Bukti terbaru pada nanas menunjukkan bahwa performa single-view untuk klasifikasi kemanisan masih terbatas ketika petunjuk visual tersebar di sisi buah yang berbeda, sedangkan fusi multi-view berbasis attention dapat meningkatkan akurasi secara nyata dibanding baseline satu sudut pandang (Vernanda et al., 2026). Oleh karena itu, sebelum mengadopsi arsitektur multi-view yang lebih kompleks, penting untuk terlebih dahulu memetakan secara diagnostik sejauh mana detektor YOLO satu

sudut pandang mampu memisahkan tiga kategori kemanisan, kategori mana yang paling rentan tertukar, dan bagaimana pilihan ambang kepercayaan memengaruhi kompromi antara deteksi benar, false positive, dan false negative.

Berdasarkan celah tersebut, penelitian ini bertujuan untuk (1) mengukur kinerja detektor YOLOv11 satu sudut pandang dalam melokalisasi sekaligus mengklasifikasikan nanas ke dalam tiga kategori kemanisan berbasis rasio TSS/TA, dan (2) mendiagnosis pola kegagalannya secara per kelas. Kebaruan (novelty) penelitian ini tidak terletak pada usulan arsitektur baru, melainkan pada karakterisasi diagnostik yang belum dilaporkan pada studi klasifikasi kemanisan nanas terdahulu, yaitu: (a) kuantifikasi struktur kesalahan antar kategori kemanisan, yang menunjukkan bahwa kekeliruan terkonsentrasi hampir simetris pada pasangan kelas yang bertetangga dan bukan pada dua kelas ekstrem; (b) pengungkapan kesenjangan antara recall yang terbaca pada kurva pelatihan (0,78-0,90) dan proporsi instance yang benar-benar terklasifikasi benar pada ambang kepercayaan default (32-64%), yang berimplikasi langsung pada cara metrik deteksi seharusnya dilaporkan; serta (c) penyediaan baseline satu sudut pandang yang terukur pada dataset nanas lokal sebagai pembanding empiris bagi pengembangan model multi-sudut pandang berbasis attention. Dengan demikian, artikel ini diposisikan sebagai tahap diagnostik yang menjembatani, bukan sebagai hasil akhir dari rangkaian penelitian.

LANDASAN TEORI


Landasan teori penelitian ini bertumpu pada konsep bahwa kemanisan nanas berkaitan dengan rasio TSS/TA, yang umum digunakan untuk menilai kualitas internal, kematangan, dan mutu rasa buah (Qiu et al., 2023b). Pengukuran kualitas ini secara konvensional dilakukan melalui pengukuran TSS dengan refraktometer dan TA dengan titrasi, tetapi pendekatan tersebut bersifat destruktif, memerlukan ekstraksi sari buah, serta tidak efisien untuk penyortiran buah skala besar (Kumara & Hettige, 2020). Keterbatasan ini mendorong pengembangan metode non-destruktif, karena teknologi seperti VIS/NIR, SW-NIRS, NIR-HSI, dan sensor portabel telah menunjukkan kelayakan untuk mendeteksi kualitas internal nanas secara cepat dan real-time (Mohd Ali et al., 2023). Dalam konteks ini, pendekatan berbasis computer vision juga relevan karena ciri tampilan luar seperti warna dan tekstur memiliki hubungan dengan kualitas internal, meskipun hubungan itu tidak selalu merepresentasikan rasa secara langsung. Oleh karena itu, penggunaan model deteksi sebagai baseline satu sudut pandang tetap masuk akal untuk menilai sejauh mana informasi visual eksternal saja dapat digunakan dalam mengklasifikasikan kategori kemanisan nanas sebelum beralih ke pendekatan yang lebih kompleks.

METODE PENELITIAN

Penelitian ini mengikuti alur kerja deteksi objek yang sederhana: penyiapan dataset, pelatihan model, dan evaluasi. Berbeda dengan pendekatan fusi multi-sudut pandang yang dieksplorasi pada bagian lain dari program penelitian ini, model pada eksperimen ini hanya menerima satu citra per buah dan langsung memprediksi bounding box beserta label kategori kemanisannya, mengikuti formulasi deteksi YOLO standar.

Dataset dan Definisi Kelas

Citra nanas diberi anotasi bounding box dan dikelompokkan ke dalam salah satu dari tiga kategori kemanisan-Asam, Manis Ideal, dan Sangat Manis-mengikuti konvensi pengelompokan berbasis rasio TSS/TA yang sama dengan penelitian terkait sebelumnya (Nugraha Purnawan et al., n.d.; Vernanda et al., 2026) Dataset yang dihasilkan berisi total 4.475 instance berlabel, terdiri dari 1.727 instance Asam, 1.767 instance Manis Ideal, dan 981 instance Sangat Manis. Manis Ideal dan Asam terwakili dalam jumlah yang relatif setara, sementara Sangat Manis jauh lebih sedikit representasinya, yaitu sekitar 55% dari jumlah instance dua kelas lainnya-suatu tingkat ketidakseimbangan kelas yang secara umum diketahui dapat menurunkan kinerja deep learning terhadap kelas minoritas(Johnson & Khoshgoftaar, 2019; Miftahushudur et al., 2025) Statistik bounding box menunjukkan bahwa objek yang dianotasi secara konsisten berada di tengah frame dan bervariasi cukup moderat pada lebar dan tingginya, sesuai dengan pengaturan pemotretan objek tunggal yang terkontrol.



Gambar 1. Distribusi Dataset Nanas

Praproses dan Konfigurasi Pelatihan

Citra diproses mengikuti pipeline pelatihan YOLOv11 standar, termasuk pengubahan ukuran (resize) ke resolusi input model dan normalisasi sebelum pelatihan. Model dilatih selama 50 epoch, dengan fungsi loss deteksi YOLO standar yang terdiri atas komponen regresi bounding box (box_loss), komponen klasifikasi (cls_loss), dan komponen distribution focal loss (dfl_loss), yang dipantau secara terpisah pada split pelatihan dan validasi di setiap epoch.

Metrik Evaluasi

Kinerja model dinilai menggunakan metrik deteksi objek standar: precision, recall, mean Average Precision pada ambang IoU 0,5 (mAP@0.5), dan mean Average Precision yang dirata-ratakan pada rentang ambang IoU 0,5 hingga 0,95 (mAP@0.5:0.95). Kurva precision-confidence, recall-confidence, dan F1-confidence digunakan untuk melihat bagaimana metrik-metrik tersebut berubah terhadap ambang kepercayaan deteksi, sementara confusion matrix pada ambang kepercayaan default digunakan untuk mengkarakterisasi pola kesalahan spesifik antar kelas maupun terhadap background.

HASIL DAN PEMBAHASAN

Pada Gambar 2 ditampilkan hasil deteksi tingkat kemanisan buah nanas berdasarkan dataset yang sudah di training sebelumnya. Hal tersebut menunjukkan bahwa model sudah mampu mendeteksi tingkat kemanisan buah nanas, meskipun secara akurasi masih belum optimal.




Gambar 2. Hasil Deteksi

Konvergensi Pelatihan

Gambar 3 merangkum kurva pelatihan dan validasi sepanjang 50 epoch. Loss pelatihan (box_loss, cls_loss, dfl_loss) menurun secara halus dan konsisten, menandakan model mampu menyesuaikan diri dengan data pelatihan tanpa instabilitas. Loss validasi mengikuti tren penurunan yang secara umum serupa namun tampak lebih berfluktuasi, dengan lonjakan yang jelas di sekitar epoch 5 dan epoch 19-20 sebelum kembali menurun. Pola ini umumnya terkait

dengan set validasi yang relatif kecil dibanding keragaman kelasnya, sehingga beberapa sampel yang sulit atau ambigu dapat sementara mendominasi nilai loss validasi pada epoch tertentu. Precision(B) meningkat dari sekitar 0,29 di awal pelatihan menjadi sekitar 0,45 pada epoch ke-50, mengikuti tren naik yang sebagian besar monoton. Sebaliknya, Recall(B) berfluktuasi dalam rentang yang cukup lebar, sekitar 0,78-0,90, sepanjang pelatihan tanpa peningkatan monoton yang jelas, yang mengindikasikan model mencapai plateau recall lebih awal sementara precision terus membaik secara bertahap-konsisten dengan model yang lebih cepat belajar menekan false positive dibanding menyelesaikan true positive yang lebih sulit. Baik $mAP@0.5(B)$ maupun $mAP@0.5:0.95(B)$ meningkat secara stabil sepanjang pelatihan, masing-masing mencapai 0,555 dan 0,460 pada epoch terakhir, tanpa tanda-tanda plateau yang jelas-menunjukkan bahwa penambahan epoch pelatihan kemungkinan masih dapat memberikan peningkatan lebih lanjut, meski cenderung semakin kecil.



Gambar 3. Hasil Training Curve

Kinerja Model dalam mendeteksi objek

Tabel 1 merangkum kinerja deteksi keseluruhan pada akhir pelatihan, sedangkan Tabel 2 memerincinya per kategori kemanisan berdasarkan kurva precision-recall (Gambar 4). Kategori Asam terdeteksi paling andal ($mAP@0.5 = 0,695$), sementara Manis Ideal (0,505) dan Sangat Manis (0,465) jauh tertinggal. Urutan ini menarik karena Manis Ideal justru merupakan kelas dengan jumlah data terbanyak dalam dataset, yang menunjukkan bahwa kinerjanya yang relatif lemah lebih disebabkan oleh ambiguitas visual dibanding kelangkaan data: sebagai kategori tengah pada skala TSS/TA, Manis Ideal berada di antara Asam dan Sangat Manis sehingga berpotensi memiliki ciri visual yang tumpang tindih dengan keduanya. Ketimpangan kinerja antar kelas yang tidak sejalan dengan jumlah data seperti ini juga dilaporkan pada tugas grading buah lain, di mana kategori mutu yang didefinisikan pada


rentang kontinu cenderung menghasilkan kinerja per kelas yang tidak merata meskipun jumlah sampelnya sebanding (Bhargava & Bansal, 2021; G et al., 2024).

Tabel 1. Metrik Evaluasi Model

Metrik	Nilai
mAP@0.5	0,555
mAP@0.5:0.95	0,460
F1-score terbaik	0,58 (pada confidence 0,183)

Tabel 2. Metrik Evaluasi Model per Kelas

Kelas	mAP@0.5	F1-score puncak
Asam	0,695	~0,66
Manis Ideal	0,505	~0,59
Sangat Manis	0,465	~0,51




Gambar 4. Precision-Recall Curve

Confusion Matrix


Confusion matrix pada ambang kepercayaan default (Gambar 5) memberikan gambaran lebih rinci mengenai di mana model berhasil dan gagal. Dari total instance Asam yang sebenarnya, 119 diprediksi benar sebagai Asam, sementara 55 diprediksi sebagai Manis Ideal dan 12 sebagai Sangat Manis; selain itu, 78 prediksi berlabel Asam ternyata merupakan background. Untuk Manis Ideal, hanya 93 yang terklasifikasi benar, dengan 58 tertukar sebagai Asam dan 59 sebagai Sangat Manis, ditambah kekeliruan background/Manis Ideal yang sangat besar, yaitu 157-sel kesalahan tunggal terbesar dalam matriks. Sangat Manis memiliki kinerja terlemah secara keseluruhan: hanya 34 prediksi benar, berbanding 38 yang tertukar dengan Manis Ideal, 12 dengan Asam, dan 79 dengan background. Tingginya kekeliruan terhadap

background merupakan pola yang lazim pada penerapan detektor satu tahap terhadap objek buah dengan latar yang beragam, terutama ketika sebagian kelas kurang terwakili (G et al., 2024; Wan Nurazwin Syazwani et al., 2022).



Gambar 5. Confusion matrix

Confusion matrix yang dinormalisasi (Gambar 6) memperjelas perbedaan keandalan antar kelas: hanya 64% instance Asam yang sebenarnya berhasil diklasifikasikan dengan benar sebagai Asam, turun menjadi 49% untuk Manis Ideal, dan hanya 32% untuk Sangat Manis. Angka ini jauh lebih rendah dibanding rentang recall 0,78-0,90 yang tampak pada kurva pelatihan (Gambar 3), yang dihitung dengan cara berbeda-sebagai recall terbaik yang dapat dicapai di sepanjang kurva precision-recall, bukan pada satu ambang operasi tetap. Selisih antara keduanya menggambarkan poin praktis yang penting: recall headline suatu model pada saat pelatihan dapat terlihat jauh lebih optimis dibanding perilakunya pada ambang kepercayaan yang benar-benar dipakai untuk sebuah keputusan nyata, sehingga metrik yang dilaporkan selalu perlu dimaknai bersama ambang operasi tempat metrik tersebut dihitung. Sebagai pembandingan, studi klasifikasi kemanisan nanas terdahulu yang bekerja pada citra buah terisolasi melaporkan akurasi yang lebih tinggi (Kanjawattana et al., 2023; Siricharoen et al., 2023), namun angka tersebut tidak sepenuhnya sebanding karena tidak menanggung beban lokalisasi dan tidak diukur pada satu ambang operasi tetap.




Gambar 6. Confusion matrix yang dinormalisasi

Dua pola menonjol dari analisis kesalahan ini. Pertama, sebagian besar kekeliruan terjadi antar kategori yang berdekatan secara visual-Manis Ideal tertukar dengan kedua tetangganya secara hampir simetris (58 ke arah Asam, 59 ke arah Sangat Manis)-sementara kekeliruan antara dua kelas ekstrem, Asam dan Sangat Manis, relatif jarang terjadi (masing-masing 12 pada kedua arah). Pola ini sejalan dengan kesulitan pada kasus batas (boundary case) yang umum dilaporkan dalam literatur klasifikasi kualitas dan tingkat kematangan buah, di mana kategori yang berdekatan pada skala kontinu (misalnya unripe-half ripe-ripe pada stroberi) cenderung paling sulit dipisahkan secara visual dibanding kategori yang jaraknya jauh (Azizi et al., 2024; Bhargava & Bansal, 2021). Kedua, Sangat Manis, kelas dengan jumlah data pelatihan paling sedikit (981, sekitar 55% dari dua kelas lainnya), juga memiliki recall terendah dan kekeliruan terhadap background terbanyak, sejalan dengan dugaan bahwa kelas ini memang mendapat lebih sedikit kesempatan untuk dipelajari dengan baik-efek yang pada studi ketidakseimbangan kelas lain di bidang agrikultur terbukti dapat dikurangi dengan class-weighted loss atau oversampling terarah, yang keduanya belum diterapkan pada eksperimen ini.

Sensitivitas Ambang Kepercayaan

Kurva F1-confidence (Gambar 7) mencapai puncak 0,58 pada ambang kepercayaan keseluruhan 0,183, dengan Asam kembali mencapai batas atas individual tertinggi (~0,66) dan Sangat Manis yang terendah (~0,51). Kurva precision-confidence dan recall-confidence (tidak dibahas rinci di sini) mengikuti pola trade-off yang umum-precision naik dan recall turun seiring meningkatnya ambang kepercayaan-namun Sangat Manis menunjukkan penurunan

yang jauh lebih curam dan berfluktuasi pada ambang yang lebih tinggi dibanding dua kelas lainnya, pola yang konsisten dengan kelas berukuran kecil dan sulit dipisahkan yang menghasilkan lebih sedikit deteksi benar dengan tingkat kepercayaan tinggi. Sensitivitas ambang yang lebih tajam pada kelas minoritas ini sejalan dengan laporan bahwa ketidakseimbangan data menggeser distribusi skor kepercayaan kelas minoritas ke arah nilai yang lebih rendah (Johnson & Khoshgoftaar, 2019; Miftahushudur et al., 2025).



Gambar 7. F1-confidence Curve

KESIMPULAN

Pada artikel ini, dilaporkan eksperimen baseline deteksi objek YOLOv11 satu sudut pandang untuk klasifikasi tingkat kemanisan nanas ke dalam tiga kategori yaitu Asam, Manis Ideal, dan Sangat Manis. Setelah 50 epoch pelatihan, model mencapai $mAP@0.5$ keseluruhan sebesar 0,555 dan $mAP@0.5:0.95$ sebesar 0,460, dengan F1-score terbaik 0,58 pada ambang kepercayaan 0,183. Analisis per kelas menunjukkan kinerja yang baik untuk Asam ($mAP@0.5 = 0,695$) namun jauh lebih lemah untuk Manis Ideal (0,505) dan Sangat Manis (0,465). Analisis confusion matrix mengungkapkan bahwa hanya 32-64% instance per kelas yang terklasifikasi benar pada ambang default, dengan kesalahan paling sering terjadi antar kategori kemanisan yang berdekatan secara visual, dan kelas Sangat Manis yang kurang terwakili paling terdampak oleh ambiguitas maupun ketidakseimbangan data. Hasil ini menetapkan sebuah baseline empiris beserta sejumlah pola kegagalan konkret-kekeliruan pada kasus batas dan ketidakseimbangan kelas-yang mendasari arah multi-sudut pandang dan berbasis attention yang ditempuh pada tahap berikutnya dari penelitian ini.

DAFTAR PUSTAKA

- Azizi, H., Askari Asli-Ardeh, E., Jahanbakhshi, A., & Momeny, M. (2024). Vision-based strawberry classification using generalized and robust deep networks. *Journal of Agriculture and Food Research*, 15, 100931. <https://doi.org/10.1016/j.jafr.2023.100931>
- Badan Pusat Statistik (BPS) Kabupaten Subang. (2024). *Kabupaten Subang Dalam Angka 2024 (Subang Regency in Figures 2024)*.
- Bhargava, A., & Bansal, A. (2021). Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University - Computer and Information Sciences*, 33(3), 243–257. <https://doi.org/10.1016/j.jksuci.2018.06.002>
- G, S., K, K., Rehsi, A., Misra, A., & Mishra, M. (2024). Fruit Quality Detection: A Comparative Study of the YOLO Series. *2024 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES)*, 1–7. <https://doi.org/10.1109/ICSES63760.2024.10910838>
- Goyal, K., Kumar, P., & Verma, K. (2023). AI-based fruit identification and quality detection system. *Multimedia Tools and Applications*, 82(16), 24573–24604. <https://doi.org/10.1007/s11042-022-14188-x>
- Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(1), 27. <https://doi.org/10.1186/s40537-019-0192-5>
- Kanjanawattana, S., Teerawatthanaprapha, W., Praneetpholkhang, P., Bhakdisongkhram, G., & Weeragulpiriya, S. (2023). Pineapple Sweetness Classification Using Deep Learning Based on Pineapple Images. *Journal of Image and Graphics*, 11(1), 47–52. <https://doi.org/10.18178/joig.11.1.47-52>
- Kumara, B. A. M. S., & Hettige, K. D. T. (2020). Ripening Stage Affects the Quality of Fresh and Dehydrated Pineapples (<i>Ananas comosus</i> (L.) Merr.)<i> cv. Mauritius in Sri Lanka. Sustainable Food Production, 8, 29–37. https://doi.org/10.18052/www.scipress.com/SFP.8.29</i>
- Maimunah Mohd Ali, Norhashila Hashim, Samsuzana Abd Aziz, & O.O. Lasekan. (2020). An overview of non-destructive approaches for quality determination in pineapples. *Journal of Agricultural and Food Engineering*, 1(1), 1–7. <https://doi.org/10.37865/jafe.2020.0011>
- Miftahushudur, T., Sahin, H. M., Grieve, B., & Yin, H. (2025). A Survey of Methods for Addressing Imbalance Data Problems in Agriculture Applications. *Remote Sensing*, 17(3), 454. <https://doi.org/10.3390/rs17030454>

- Mohd Ali, M., Hashim, N., Bejo, S. K., Jahari, M., & Shahabudin, N. A. (2023). Innovative non-destructive technologies for quality monitoring of pineapples: Recent advances and applications. *Trends in Food Science & Technology*, 133, 176–188. <https://doi.org/10.1016/j.tifs.2023.02.005>
- Nugraha Purnawan, N., Vernanda, D., Herdiawan Apandi, T., & Niqotaini, Z. (n.d.). *Non-Destructive Classification Model of Pineapple Sweetness Level*. 19(1).
- Paull, R. E., Uruu, G., & Chen, N. J. (2020). Rapid Field Assay for Pineapple Fruit Acidity. *HortTechnology*, 30(5), 593–596. <https://doi.org/10.21273/HORTTECH04664-20>
- Qiu, G., Lu, H., Wang, X., Wang, C., Xu, S., Liang, X., & Fan, C. (2023a). Nondestructive Detecting Maturity of Pineapples Based on Visible and Near-Infrared Transmittance Spectroscopy Coupled with Machine Learning Methodologies. *Horticulturae*, 9(8), 889. <https://doi.org/10.3390/horticulturae9080889>
- Qiu, G., Lu, H., Wang, X., Wang, C., Xu, S., Liang, X., & Fan, C. (2023b). Nondestructive Detecting Maturity of Pineapples Based on Visible and Near-Infrared Transmittance Spectroscopy Coupled with Machine Learning Methodologies. *Horticulturae*, 9(8), 889. <https://doi.org/10.3390/horticulturae9080889>
- R., S. R., M. E., A., & M., M. (2021). Influence of post-harvest physiology on sensory perception, physical properties, and chemical compositions of Moris pineapples (*Ananas comosus* L.). *Journal of Food Science*, 86(9), 4159–4171. <https://doi.org/10.1111/1750-3841.15877>
- Sangsongfa, A., Am-Dee, N., & Meesad, P. (2020). Prediction of Pineapple Sweetness from Images Using Convolutional Neural Network. *EAI Endorsed Transactions on Context-Aware Systems and Applications*, 7(21), 165518. <https://doi.org/10.4108/eai.13-7-2018.165518>
- Siricharoen, P., Yomsatieankul, W., & Bunsri, T. (2023). Recognizing the sweet and sour taste of pineapple fruits using residual networks and green-relative color transformation attached with Mask R-CNN. *Postharvest Biology and Technology*, 196, 112174. <https://doi.org/10.1016/j.postharvbio.2022.112174>
- Vernanda, D., Apandi, T. H., Suhailla Binti Jili, A., Triastuti, D., & Muhammad Fauzi, W. (2026). Attention-Based Multi-View Fusion YOLO for Non-Destructive Pineapple Sweetness Assessment. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 10(2), 267–279. <https://doi.org/10.29207/resti.v10i2.7382>
- VIANA, E. D. S., SASAKI, F. F. C., REIS, R. C., JUNGHANS, D. T., GUEDES, I. S. A., & SOUZA, E. G. (2020). QUALITY OF FUSARIOSIS-RESISTANT PINEAPPLE FRF

632, HARVESTED AT DIFFERENT MATURITY STAGES. *Revista Caatinga*, 33(2), 541–549. <https://doi.org/10.1590/1983-21252020v33n226rc>

Wan Nurazwin Syazwani, R., Muhammad Asraf, H., Megat Syahirul Amin, M. A., & Nur Dalila, K. A. (2022). Automated image identification, detection and fruit counting of top-view pineapple crown using machine learning. *Alexandria Engineering Journal*, 61(2), 1265–1276. <https://doi.org/10.1016/j.aej.2021.06.053>