

ESTIMASI KONSENTRASI PERLAKUAN LARUTAN NUTRISI HIDROPONIK PAKCOY BERBASIS CITRA MENGGUNAKAN YOLOV8S DAN EFFICIENTNETV2-S

*(Image Based Estimation of Nutrient Solution Treatment Concentration in
Hydroponic Pakcoy Using YOLOv8s and EfficientNetV2-S)*

Aniza Wulandari^[1], Nike Dwi Grevika Drantantiyas^[1], Ahmad Suaif^[1]

^[1] Program Studi Teknik Fisika, Fakultas Teknologi Industri, Institut Teknologi Sumatera
Lampung Selatan, Lampung, Indonesia

Email: aniza.122320035@student.itera.ac.id, nike.drantantiyas@tf.itera.ac.id, ahmad.suaif@tf.itera.ac.id

Abstract

Nutrient availability is important in hydroponic pakcoy cultivation, but image-based monitoring requires a clearly defined target and a reliable estimation pipeline. This study develops and evaluates a cascaded computer-vision method using YOLOv8s to localize pakcoy leaves and EfficientNetV2-S to estimate the experimentally assigned nutrient-solution treatment concentration from leaf regions. After dataset auditing, 1,995 unique annotated images were divided into 1,595 training, 200 validation, and 200 independent test images covering 250, 500, 750, and 1,000 ppm. YOLOv8s was trained for 50 epochs with 320×320 -pixel inputs, while EfficientNetV2-S used 224×224 -pixel regions of interest, AdamW optimization, and Huber loss. On the independent test set, YOLOv8s achieved precision of 0.9173, recall of 0.8870, mean average precision at 0.50 intersection-over-union of 0.9598, and mean average precision at 0.50–0.95 of 0.8428, with usable leaf regions obtained from 170 of 200 images. Conditional on successful localization, EfficientNetV2-S achieved a mean absolute error of 42.76 ppm, root mean square error of 107.37 ppm, mean absolute percentage error of 5.71%, and R-squared of 0.8577. The results support detector-guided estimation within the four observed treatment levels, while generalization to unseen concentrations and cultivation conditions remains unvalidated.

Keywords: Pakcoy, Hydroponics, Leaf Images, Nutrient Solution Treatment Concentration, YOLOv8s, EfficientNetV2-S

1. PENDAHULUAN

Ketersediaan nutrisi merupakan salah satu faktor penting dalam pertumbuhan dan produktivitas tanaman karena unsur hara makro dan mikro mendukung berbagai proses fisiologis. Pada budidaya hidroponik, suplai nutrisi diberikan melalui larutan sehingga konsentrasi larutan menjadi salah satu variabel penting dalam pengelolaan dan eksperimen budidaya. Pakcoy (*Brassica rapa* L.) merupakan sayuran daun yang banyak dibudidayakan secara hidroponik, dan perubahan ketersediaan nutrisi dapat berkaitan dengan perubahan pertumbuhan serta karakteristik visual daun [1], [2].

Karakteristik visual seperti warna, tekstur, dan bentuk daun dapat direkam menggunakan kamera digital kemudian dianalisis secara komputasional. Pendekatan berbasis citra telah digunakan untuk mengestimasi variabel yang berkaitan dengan nitrogen dan status nutrisi pada berbagai tanaman, baik menggunakan citra RGB maupun citra hiperspektral [3], [4]. Pendekatan tersebut menunjukkan bahwa

informasi visual dapat digunakan sebagai sumber informasi non-destruktif, tetapi makna biologis prediksi sangat bergantung pada definisi target dan cara memperoleh nilai acuan.

Penilaian status nutrisi secara konvensional umumnya memerlukan pengambilan sampel dan pengukuran menggunakan instrumen atau analisis laboratorium. Prosedur tersebut dapat memberikan informasi kimia secara langsung, tetapi pengukuran berulang membutuhkan waktu dan sumber daya tambahan serta dapat melibatkan pengambilan jaringan tanaman. Pemodelan berbasis citra dapat menjadi pendekatan komplementer untuk pemantauan berulang apabila hubungan antara karakteristik visual dan variabel target dapat dibangun dan divalidasi [5], [6].

Penelitian sebelumnya telah menunjukkan beberapa bentuk estimasi nutrisi berbasis citra. Citra RGB dan pembelajaran mesin telah digunakan untuk mengestimasi variabel nitrogen pada padi dan tebu, sedangkan citra hiperspektral telah digunakan untuk memprediksi konsentrasi beberapa unsur pada

tanaman selada hidroponik. Pada pakcoy hidroponik, pengolahan citra juga telah digunakan untuk membedakan kondisi yang berkaitan dengan perlakuan larutan nutrisi, tetapi pendekatan tersebut belum sama dengan alur deteksi objek yang dilanjutkan regresi numerik pada wilayah daun [3], [7].

Dalam penelitian ini, target 250, 500, 750, dan 1.000 ppm diperlakukan sebagai tingkat perlakuan konsentrasi larutan nutrisi yang ditetapkan pada sampel eksperimen. Nilai tersebut merupakan label operasional untuk perlakuan dan bukan pengukuran langsung konsentrasi unsur hara di dalam jaringan daun. Karena data hanya mencakup empat tingkat yang diamati, keluaran model di antara tingkat tersebut diperlakukan sebagai estimasi numerik dalam rentang eksperimen dan tidak dianggap sebagai bukti validasi interpolasi pada konsentrasi yang belum diamati.

Citra masukan dapat mengandung latar belakang yang tidak berkaitan langsung dengan daun sehingga tahap lokalisasi dapat digunakan untuk membatasi informasi yang diteruskan ke model regresi. Arsitektur YOLO banyak digunakan untuk mendeteksi dan melokalisasi objek secara efisien, termasuk pada analisis citra pertanian. Pada penelitian ini, *YOLOv8s* digunakan sebagai tahap penyaringan spasial, sedangkan *EfficientNetV2-S* digunakan untuk mengubah informasi visual dari wilayah daun menjadi estimasi numerik [8], [9].

Kontribusi metodologis penelitian ini ditempatkan pada alur regresi yang dipandu detektor, bukan pada penciptaan arsitektur jaringan saraf baru. *YOLOv8s* menghasilkan koordinat wilayah daun yang kemudian digunakan untuk membentuk *Region of Interest* (RoI), sedangkan *EfficientNetV2-S* menerima RoI tersebut sebagai masukan regresi. *EfficientNetV2* dikembangkan dengan perhatian pada efisiensi pelatihan dan penggunaan parameter sehingga dapat diadaptasi untuk keluaran numerik [10], [11].

Tujuan penelitian adalah mengembangkan dan mengevaluasi alur sistem *YOLOv8s-EfficientNetV2-S* untuk mengestimasi konsentrasi perlakuan larutan nutrisi hidroponik pada pakcoy berdasarkan citra daun. Evaluasi mencakup kinerja deteksi, kinerja regresi pada citra uji yang berhasil dilokalisasi, serta hubungan antara keberhasilan lokalisasi dan estimasi numerik. Penelitian juga membatasi interpretasi hasil berdasarkan empat tingkat perlakuan, kondisi akuisisi yang tersedia, dan belum adanya validasi eksternal.

2. TINJAUAN PUSTAKA

Penilaian nutrisi berbasis citra dapat dipandang sebagai pemetaan dari karakteristik visual tanaman

menuju target nutrisi yang didefinisikan secara spesifik. Citra RGB telah digunakan bersama pembelajaran mesin untuk mengestimasi variabel nitrogen pada tanaman, sedangkan pencitraan hiperspektral digunakan untuk memprediksi beberapa konsentrasi unsur pada selada hidroponik [3], [12]. Perbedaan target, metode pengukuran acuan, jenis tanaman, dan modalitas citra menunjukkan bahwa nilai kinerja antar penelitian tidak dapat dibandingkan secara langsung tanpa mempertimbangkan konteks eksperimennya. Pada ranah pengenalan pola berbasis citra tanaman, kombinasi fitur warna, tekstur, dan bentuk juga telah digunakan untuk membedakan kondisi visual objek secara otomatis [13].

Pembelajaran mendalam memberikan alternatif terhadap fitur citra yang dirancang secara manual karena jaringan konvolusional dapat mempelajari representasi warna, tekstur, bentuk, dan pola spasial dari citra. Berbagai penelitian telah menggunakan jaringan mendalam untuk diagnosis defisiensi nutrisi maupun estimasi karakteristik terkait nutrisi pada tanaman. Hasil tersebut mendukung penggunaan fitur visual yang dipelajari model, tetapi juga menunjukkan bahwa kinerja sangat dipengaruhi oleh jenis tanaman, definisi target, modalitas citra, dan kondisi eksperimen [12], [11].

Deteksi objek menambahkan informasi spasial dengan menentukan lokasi objek yang menjadi perhatian di dalam citra. Keluarga YOLO menggabungkan proses lokalisasi dan klasifikasi dalam kerangka deteksi yang efisien dan telah banyak digunakan pada aplikasi pertanian [8], [10]. Dalam alur sistem bertingkat, kotak pembatas dari detektor dapat dikonversi menjadi RoI sehingga model berikutnya memproses wilayah yang telah difokuskan pada objek target.

YOLOv8s merupakan varian ringan dari keluarga *YOLOv8* yang sesuai untuk kebutuhan deteksi dengan pertimbangan kemampuan dan biaya komputasi. *EfficientNetV2-S* memiliki rancangan yang menekankan efisiensi pelatihan dan dapat diadaptasi dari keluaran klasifikasi menjadi satu keluaran numerik untuk regresi [8], [14]. Kombinasi keduanya memberikan pembagian fungsi yang jelas, yaitu *YOLOv8s* untuk lokalisasi spasial dan *EfficientNetV2-S* untuk estimasi numerik.

Penggunaan alur sistem detektor-regresor perlu dibedakan dari klaim bahwa model melakukan pengukuran nutrisi secara kausal atau biologis. Karakteristik visual daun dapat dipengaruhi oleh umur tanaman, tahap perkembangan, pencahayaan, status air, penyakit, suhu, paparan kamera, dan faktor

budidaya lainnya. Oleh karena itu, kinerja tinggi pada dataset terbatas tidak dengan sendirinya membuktikan validitas biologis atau generalisasi pada kondisi yang berbed [3], [5].

Penelitian ini menempatkan *YOLOv8s* sebagai mekanisme untuk menentukan wilayah daun dan *EfficientNetV2-S* sebagai model regresi terhadap tingkat perlakuan larutan nutrisi yang telah ditetapkan. Pertanyaan metodologis utamanya adalah apakah Rol hasil detektor dapat menjadi representasi yang sesuai untuk tahap regresi, bukan apakah kedua arsitektur tersebut merupakan desain jaringan saraf baru. Karena hanya empat tingkat target tersedia, penelitian ini diposisikan sebagai pembuktian konsep untuk estimasi pada tingkat perlakuan yang diamati.

TABEL I. RINGKASAN STATE OF THE ART DAN POSISI PENELITIAN

Penelitian	Target dan Metode	Keterbatasan/Gap
Chang et al. [1]	Nitrogen tanaman; pemodelan berbasis citra	Target berbeda dari tingkat perlakuan nutrisi pakcoy
You et al. [3]	Nitrogen tebu; <i>machine learning</i> berbasis citra	Objek berbeda dan belum menggunakan pipeline deteksi-regresi
Rosyidah et al. [7]	AB MIX pakcoy; <i>image processing</i>	AB MIX pakcoy; <i>image processing</i>
Ahsan et al. [12]	Nutrisi hidroponik; <i>deep learning</i>	Tanaman dan konfigurasi berbeda
Penelitian ini	250–1.000 ppm pakcoy; <i>YOLOv8s</i> – <i>EfficientNetV2-S</i>	Evaluasi pada empat tingkat; ablation dan baseline belum dilakukan

3. METODE PENELITIAN

3.1. Persiapan Data dan Audit

Dataset yang digunakan dalam penelitian ini diperoleh dari penelitian Tugas Akhir sebelumnya yang dilakukan oleh mahasiswa pada lingkungan penelitian yang sama [15]. Dataset tersebut dapat diakses melalui *repository* GitHub [16]. Dataset tersebut kemudian digunakan sebagai sumber data sekunder untuk pengembangan dan evaluasi metode pada penelitian


ini, dengan fokus pada pengembangan pipeline *YOLOv8s*–*EfficientNetV2-S* untuk mengestimasi tingkat perlakuan konsentrasi larutan nutrisi berdasarkan citra daun pakcoy. Dataset awal terdiri atas 1.997 citra yang telah tersedia beserta struktur anotasi dan kemudian dilakukan audit serta deduplikasi sebelum digunakan dalam pembagian dataset pada penelitian ini.

Dataset awal terdiri atas 1.997 berkas citra fisik yang tersimpan pada folder pelatihan, validasi, dan uji. Audit menemukan citra 1000_0002.jpg yang tidak memiliki anotasi pelatihan yang sesuai, meskipun citra identik dengan anotasi valid terdapat pada folder uji awal. Audit juga menemukan pasangan konten duplikat antara 250_0010.jpg dan 250_0464.jpg; satu anggota dari setiap masalah tersebut dikeluarkan sebelum pembentukan *split* akhir.

Setelah audit dan deduplikasi, diperoleh 1.995 pasangan citra-label unik. Dataset kemudian dibagi ulang menggunakan seed 42 menjadi 1.595 citra pelatihan, 200 citra validasi, dan 200 citra data uji independen. Stratifikasi dilakukan berdasarkan empat tingkat perlakuan sehingga validasi dan uji masing-masing berisi 50 citra untuk 250, 500, 750, dan 1.000 ppm. Jumlah citra tersebut merepresentasikan jumlah observasi citra, bukan jumlah tanaman atau individu tanaman yang berbeda.


Nilai 250, 500, 750, dan 1.000 ppm digunakan sebagai label tingkat perlakuan konsentrasi larutan nutrisi yang ditetapkan pada sampel. Label tersebut tidak diperlakukan sebagai pengukuran langsung kandungan nutrisi di jaringan daun karena tidak tersedia analisis kimia atau instrumental jaringan yang independen. Dokumentasi yang tersedia juga tidak memuat identitas tanaman, *batch*, sesi akuisisi, kamera, jarak, sudut, pencahayaan, atau pengukuran berulang secara lengkap sehingga pemisahan berbasis kelompok tidak dapat diverifikasi. Dengan demikian, istilah data uji independen dalam artikel ini merujuk pada pemisahan file/citra dari proses pelatihan dan pemilihan model, sedangkan independensi pada tingkat tanaman belum dapat diverifikasi.

Pembagian dataset pada penelitian ini dilakukan pada tingkat citra setelah proses audit dan deduplikasi. Data uji tidak digunakan dalam proses pelatihan maupun pemilihan *checkpoint* model, sehingga pemisahan data dapat dinyatakan independen pada tingkat file/citra. Namun, independensi pada tingkat tanaman belum dapat diverifikasi karena dokumentasi yang tersedia tidak memuat identitas tanaman, *batch*, dan sesi akuisisi secara lengkap.



Gambar 1. Tahapan Penelitian dan Alur Estimasi Konsentrasi

Gambar 1 menunjukkan alur penelitian mulai dari persiapan data dan pelatihan detektor, pembentukan RoI, pelatihan model regresi, hingga pengujian dan analisis metrik. Alur bertingkat tersebut memisahkan fungsi lokalisasi daun dari estimasi konsentrasi. Tahap pengujian dilakukan setelah model dipilih menggunakan data validasi.



Gambar 2. Kondisi Daun Pakcoy Pada Empat Tingkat Perlakuan: (a) 250 ppm, (b) 500 ppm, (c) 750 ppm, (d) 1.000 ppm

Gambar 2 memperlihatkan contoh citra daun pakcoy yang diperoleh dari sampel dengan empat tingkat perlakuan konsentrasi larutan nutrisi, yaitu 250, 500, 750, dan 1.000 ppm. Citra daun digunakan sebagai masukan visual untuk mempelajari hubungan antara karakteristik tampak daun dan tingkat perlakuan larutan nutrisi yang diberikan pada tanaman. Nilai konsentrasi tersebut merupakan label perlakuan eksperimen dan tidak diinterpretasikan sebagai hasil pengukuran langsung kandungan nutrisi di dalam jaringan daun.

TABEL II. PEMBAGIAN DATASET DAN KONFIGURASI PELATIHAN

Parameter	Nilai
Dataset dan <i>split</i>	1.995 pasangan unik; 1.595 <i>train</i> , 200 validasi, 200 <i>test</i>
Tingkat perlakuan	250, 500, 750, 1.000 ppm
<i>YOLOv8s</i>	320 × 320 piksel; 50 <i>epoch</i> ; <i>batch</i> 16
Optimasi <i>YOLOv8s</i>	AdamW; LR 0,001; WD 0,0005; <i>cosine</i> ; augmentasi tercatat
<i>EfficientNetV2-S</i>	RoI 224 × 224; <i>pretrained</i> ; maksimum 50 <i>epoch</i> ; <i>batch</i> 4
Optimasi regresi	AdamW; LR 0,0001; WD 0,0001; <i>cosine</i> ; <i>Huber</i> ; <i>early stopping</i> 20
Inferensi dan normalisasi	<i>Confidence</i> ≥ 0,50; <i>confidence</i> tertinggi untuk multi-deteksi; gagal tidak diganti citra penuh; ImageNet <i>normalization</i>

Tabel II merangkum konfigurasi akhir yang digunakan setelah audit dataset dan pelatihan ulang. Partisi uji tidak digunakan untuk pemilihan *checkpoint* dan hanya digunakan untuk evaluasi akhir. Konfigurasi tersebut merupakan konfigurasi akhir yang digunakan pada eksperimen.

3.2. Arsitektur Sistem

Alur penelitian terdiri atas persiapan data, pelatihan detektor, pembentukan RoI, pelatihan regresor, dan pengujian. *YOLOv8s* digunakan sebagai tahap deteksi untuk mengidentifikasi objek daun pakcoy pada citra. Objek deteksi didefinisikan sebagai kelas *pakcoy_leaf*, dengan satu *bounding box* merepresentasikan satu daun yang dianotasi sebagai objek target. Keluaran detektor berupa koordinat *bounding box* dan nilai *confidence* kemudian digunakan sebagai dasar pembentukan RoI untuk tahap estimasi.

3.3. Pelatihan Model dan Pembentukan RoI

YOLOv8s dilatih selama 50 *epoch* dengan ukuran *batch* 16 dan ukuran masukan 320 × 320 piksel menggunakan AdamW, laju pembelajaran awal 0,001, bobot peluruhan 0,0005, dan *cosine learning-rate scheduling*. Model diinisialisasi dari bobot pralatih dan hanya dilatih pada partisi pelatihan, sedangkan partisi validasi digunakan untuk pemantauan dan pemilihan model. Konfigurasi augmentasi yang tercatat mencakup *mosaic*, horizontal *flip* dengan probabilitas 0,5, perubahan HSV masing-masing 0,015, 0,7, dan 0,4,

scale 0,5, translation 0,1, serta penutupan *mosaic* pada 10 *epoch* terakhir; operasi *Blur*, *MedianBlur*, *ToGray*, dan *CLAHE* juga tercatat dengan probabilitas 0,01.


Dalam proses pelatihan YOLOv8s, kelas objek yang digunakan adalah *pakcoy_leaf*. Setiap *bounding box* pada anotasi merepresentasikan satu daun pakcoy yang menjadi objek target deteksi. Model kemudian mempelajari lokasi objek tersebut dan menghasilkan prediksi koordinat *bounding box* beserta nilai *confidence*. Prediksi tersebut selanjutnya digunakan untuk membentuk RoI pada tahap regresi.

Setelah proses deteksi menggunakan YOLOv8s, hasil *bounding box* prediksi digunakan untuk membentuk *Region of Interest* (RoI) sebagai masukan bagi *EfficientNetV2-S*. Dengan demikian, RoI pada *pipeline* regresi diperoleh dari hasil prediksi detektor, bukan dari *bounding box ground truth*. *Bounding box ground truth* digunakan sebagai acuan anotasi pada proses pelatihan dan evaluasi YOLOv8s, sedangkan keluaran prediksi YOLOv8s digunakan untuk menentukan wilayah citra yang diteruskan ke tahap regresi.

Pada tahap inferensi, hanya deteksi dengan nilai *confidence* minimal 0,50 yang digunakan untuk membentuk RoI. Apabila terdapat lebih dari satu deteksi pada suatu citra, deteksi dengan nilai *confidence* tertinggi digunakan sebagai RoI yang diteruskan ke tahap regresi. Citra yang tidak menghasilkan deteksi yang memenuhi ambang tersebut tidak diteruskan ke *EfficientNetV2-S*. Analisis sensitivitas terhadap beberapa nilai *confidence threshold* belum dilakukan sehingga nilai 0,50 tidak dinyatakan sebagai nilai yang paling optimal.

EfficientNetV2-S menggunakan RoI 224×224 piksel dan bobot pralatih. Pelatihan menggunakan maksimum 50 *epoch*, ukuran *batch* 4, AdamW, laju pembelajaran 0,0001, bobot peluruhan 0,0001, *cosine annealing*, *Huber loss*, normalisasi ImageNet, dan *early stopping* dengan *patience* 20 *epoch*. Model terbaik dipilih berdasarkan MAE validasi terendah dan checkpoint terpilih berada pada *epoch* ke-38 dengan MAE validasi 46,4512 ppm.

Gambar 3 memperlihatkan pemisahan fungsi dua model. YOLOv8s menentukan lokasi daun melalui *bounding box*, kemudian RoI hasil deteksi diproses oleh *EfficientNetV2-S* untuk menghasilkan estimasi numerik konsentrasi perlakuan. Pemisahan fungsi ini menjadi dasar rancangan alur sistem penelitian.



Gambar 3. Arsitektur Berjenjang YOLOv8s dan *EfficientNetV2-S*

3.4. Pengujian dan Evaluasi

Detektor dievaluasi pada 200 citra uji menggunakan *precision*, *recall*, $\text{mAP}@0,50$, dan $\text{mAP}@0,50:0,95$. Regresor dievaluasi pada RoI yang berhasil dibentuk menggunakan MAE, RMSE, MAPE, dan R^2 , kemudian dilengkapi dengan MAE, bias, simpangan baku galat, serta interval kepercayaan 95% berdasarkan *bootstrap* pada tingkat citra. Prosedur pengujian memisahkan validasi dari uji sehingga uji hanya digunakan untuk evaluasi akhir setelah pelatihan ulang pada *split* yang telah dikoreksi.

MAE dihitung sebagai rata-rata nilai absolut selisih antara nilai perlakuan referensi dan prediksi. RMSE memberikan penalti lebih besar terhadap galat yang besar, sedangkan MAPE menyatakan galat relatif terhadap nilai aktual dalam bentuk persentase. Koefisien determinasi R^2 digunakan untuk menggambarkan proporsi variasi nilai aktual yang dijelaskan oleh prediksi model.

$$\text{MAE} = \left(\frac{1}{n}\right) \sum |y_i - \hat{y}_i| \quad (1)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Pada Persamaan (1)–(4), y_i adalah nilai perlakuan referensi, $\hat{y}_i$ adalah konsentrasi hasil estimasi, $\bar{y}$ adalah rata-rata nilai perlakuan referensi, dan n adalah jumlah sampel. Keempat metrik digunakan secara konsisten pada evaluasi regresi.

4. HASIL DAN PEMBAHASAN

Proses pelatihan *YOLOv8s* selama 50 *epoch* menunjukkan penurunan *box loss*, *classification loss*, dan *distribution focal loss*, sementara *precision*, *recall*, *mAP@0,50*, dan *mAP@0,50:0,95* secara umum meningkat. Kurva tersebut menunjukkan bahwa model mempelajari representasi visual untuk lokalisasi daun selama pelatihan. Gambar 4 menampilkan keseluruhan kurva pelatihan dan metrik evaluasi.

4.1. Kinerja Deteksi

Pada partisi data uji independen yang terdiri atas 200 citra, *YOLOv8s* menghasilkan *precision* 0,9173, *recall* 0,8870, *mAP@0,50* sebesar 0,9598, dan *mAP@0,50:0,95* sebesar 0,8428. Nilai tersebut diperoleh dari checkpoint terbaik yang dievaluasi pada uji terpisah sehingga tidak dihitung dari kurva pelatihan atau validasi. Hasil ini menunjukkan lokalisasi yang kuat pada *IoU* 0,50, tetapi *recall* yang lebih rendah menunjukkan bahwa tidak semua citra berhasil dilokalisasi.

Pada *confidence* 0,50, sebanyak 168 dari 200 citra menghasilkan satu deteksi dan dua citra menghasilkan lebih dari satu deteksi. Sebanyak 30 citra tidak menghasilkan deteksi di atas ambang sehingga cakupan RoI untuk tahap regresi adalah 170/200 atau 85,0%. Dua kasus multi-deteksi ditangani dengan mempertahankan kotak dengan *confidence* tertinggi, sedangkan 30 kasus gagal tidak dimasukkan ke evaluasi regresi bersyarat.

TABEL III. KINERJA *YOLOv8s* PADA DATA UJI INDEPENDEN

Metrik	Hasil Uji Independen
<i>Precision</i>	0,9173
<i>Recall</i>	0,8870
<i>mAP@0,50</i>	0,9598
<i>mAP@0,50:0,95</i>	0,8428
Citra <i>test</i>	200
RoI <i>usable</i>	170 (85,0%)

Tabel III menunjukkan bahwa Pada ambang *confidence* 0,50, *YOLOv8s* menghasilkan RoI yang dapat diteruskan ke tahap regresi pada 170 dari 200 citra uji atau sebesar 85,0%. Cakupan RoI berbeda antar tingkat perlakuan. Dari masing-masing 50 citra,

RoI berhasil diperoleh pada 43 citra (86,0%) untuk 250 ppm, 40 citra (80,0%) untuk 500 ppm, 41 citra (82,0%) untuk 750 ppm, dan 46 citra (92,0%) untuk 1.000 ppm. Sebanyak 30 citra tidak menghasilkan deteksi yang memenuhi ambang *confidence*, sedangkan pada 2 citra terdapat lebih dari satu deteksi dan deteksi dengan *confidence* tertinggi digunakan untuk membentuk RoI.

TABEL IV. KINERJA REGRESI *EfficientNetV2-S* BERDASARKAN TINGKAT PERLAKUAN

Perlakuan (ppm)	n	MAE (ppm)	RMSE (ppm)	MAPE (%)
250	43	7,14	15,01	2,85
500	40	18,22	44,83	3,64
750	41	57,44	82,41	7,66
1.000	46	84,33	186,00	8,43

Tabel IV memperlihatkan peningkatan MAE dan RMSE pada tingkat perlakuan yang lebih tinggi. MAPE juga meningkat dari 2,85% pada 250 ppm menjadi 8,43% pada 1.000 ppm. Pola ini menunjukkan bahwa kesalahan prediksi tidak seragam pada seluruh rentang perlakuan.

TABEL V. BIAS, SIMPANGAN BAKU GALAT, DAN INTERVAL KEPERCAYAAN MAE

Perlakuan (ppm)	Bias (ppm)	SD galat (ppm)	MAE 95% CI (ppm)
250	-0,52	15,18	4,00–11,48
500	-1,48	45,37	9,36–32,52
750	-33,08	76,41	40,68–77,46
1.000	-59,25	178,26	48,94–143,68


Tabel V menunjukkan kecenderungan bias negatif yang semakin besar pada tingkat perlakuan 750 dan 1.000 ppm. Selain itu, simpangan baku galat meningkat pada kedua tingkat tersebut, yang menunjukkan penyebaran kesalahan prediksi yang lebih besar. Interval kepercayaan 95% untuk MAE memberikan informasi mengenai ketidakpastian estimasi kinerja pada masing-masing tingkat perlakuan. Interval tersebut dihitung menggunakan prosedur *bootstrap* pada tingkat citra.

4.2. Kinerja Regresi

Regresi *EfficientNetV2-S* pada 170 RoI yang berhasil dilokalisasi menghasilkan MAE 42,7641 ppm, RMSE 107,3727 ppm, MAPE 5,7084%, dan R^2 0,8577. Hasil ini merupakan kinerja bersyarat setelah keberhasilan deteksi dan bukan kinerja *end-to-end* untuk seluruh 200 citra. Interval *bootstrap* 95% menghasilkan


rentang 30,5811–58,8621 ppm untuk MAE, 53,5193–164,7186 ppm untuk RMSE, 4,2855–7,4760% untuk MAPE, dan 0,6567–0,9649 untuk R^2 .

Kinerja per tingkat perlakuan menunjukkan bahwa kesalahan meningkat pada konsentrasi yang lebih tinggi. Pada 250 ppm, MAE adalah 7,14 ppm; pada 500 ppm, MAE 18,22 ppm; pada 750 ppm, MAE 57,44 ppm; sedangkan pada 1.000 ppm, MAE 84,33 ppm, sebagaimana diringkas pada Tabel III. Bias dan simpangan baku galat pada Tabel IV menunjukkan kecenderungan *underestimation* yang semakin besar pada 750 dan 1.000 ppm.



Gambar 4. Kurva Loss dan Metrik Evaluasi YOLOv8s Selama Pelatihan

Gambar 4 menunjukkan tren pelatihan dan validasi selama 50 *epoch*. Loss utama menurun secara umum, sedangkan metrik deteksi meningkat dan kemudian berfluktuasi pada bagian akhir pelatihan. Kurva ini digunakan untuk memeriksa proses pembelajaran model selama pelatihan.



Gambar 5. Nilai Nilai perlakuan referensi dan Prediksi pada Rol Uji Independen

Gambar 5 memperlihatkan hubungan antara nilai perlakuan referensi dan prediksi pada 170 Rol uji. Empat kelompok vertikal pada sumbu nilai perlakuan referensi mencerminkan empat tingkat perlakuan yang tersedia, sehingga sebaran prediksi tidak dapat dibaca sebagai bukti validasi kontinu pada konsentrasi yang belum diamati. Penyimpangan yang lebih besar dari garis prediksi ideal terlihat terutama pada 750 dan 1.000 ppm, konsisten dengan Tabel III dan Tabel IV.

4.3. Pembahasan

Audit dataset dan pembentukan ulang partisi data memberikan dasar evaluasi yang lebih terkontrol dibandingkan alur awal penelitian. Setelah citra yang tidak memiliki pasangan anotasi dan salah satu citra duplikat dikeluarkan, pembagian data dilakukan kembali sebelum pelatihan ulang sehingga partisi uji dapat dipertahankan sebagai data independen. Pada pengujian tersebut, YOLOv8s menghasilkan *precision* sebesar 0,9173, *recall* sebesar 0,8870, *mAP@0,50* sebesar 0,9598, dan *mAP@0,50:0,95* sebesar 0,8428, sedangkan EfficientNetV2-S menghasilkan MAE sebesar 42,76 ppm pada citra yang berhasil dilokalisasi. Hasil tersebut menunjukkan bahwa tahap deteksi mampu menyediakan lokalisasi daun yang memadai sebagai masukan bagi tahap regresi, meskipun keberhasilan deteksi tetap menjadi salah satu faktor pembatas kinerja sistem secara keseluruhan.

Meskipun demikian, independensi data uji perlu dipahami sesuai dengan tingkat informasi yang tersedia. Pemisahan *train-validation-test* memastikan bahwa citra pada partisi uji tidak digunakan untuk pelatihan maupun pemilihan model, tetapi belum menjamin independensi pada tingkat tanaman atau sesi akuisisi. Apabila terdapat beberapa citra yang berasal dari tanaman atau sesi pengambilan yang sama dan tersebar pada partisi berbeda, *random split* berpotensi menghasilkan estimasi performa yang lebih optimistis. Oleh karena itu, hasil pengujian pada penelitian ini perlu dipahami sebagai evaluasi pada pemisahan tingkat citra, sedangkan validasi berbasis kelompok tanaman, *batch*, atau sesi akuisisi masih diperlukan untuk menguji generalisasi secara lebih ketat.

Pada ambang *confidence* 0,50, sebanyak 170 dari 200 citra uji menghasilkan *Region of Interest* (Rol) yang dapat diproses oleh EfficientNetV2-S, sedangkan 30 citra tidak menghasilkan deteksi yang memenuhi ambang tersebut. Dengan demikian, cakupan deteksi sebesar 85,0% menunjukkan bahwa tidak seluruh citra uji dapat diteruskan ke tahap estimasi konsentrasi. Metrik regresi yang diperoleh karenanya

merepresentasikan kinerja bersyarat (*conditional performance*) pada citra dengan lokalisasi yang berhasil, bukan kinerja *end-to-end* terhadap seluruh citra uji. Interpretasi sistem perlu mempertimbangkan kedua tahap tersebut secara bersamaan karena peningkatan akurasi regresi tidak dapat menghilangkan kegagalan pada tahap deteksi.

Kinerja regresi menunjukkan variasi galat yang cukup jelas antar tingkat perlakuan. MAE meningkat dari 7,14 ppm pada 250 ppm menjadi 18,22 ppm pada 500 ppm, 57,44 ppm pada 750 ppm, dan 84,33 ppm pada 1.000 ppm. Selain itu, bias negatif sebesar -33,08 ppm pada 750 ppm dan -59,25 ppm pada 1.000 ppm menunjukkan kecenderungan model menghasilkan estimasi lebih rendah daripada nilai perlakuan referensi pada kedua tingkat tersebut. Kecenderungan tersebut disertai peningkatan simpangan baku galat, yaitu 76,41 ppm pada 750 ppm dan 178,26 ppm pada 1.000 ppm. Kombinasi bias negatif dan penyebaran galat yang lebih besar menunjukkan bahwa pada kedua tingkat perlakuan tersebut model tidak hanya cenderung mengalami *underestimation*, tetapi juga menghasilkan prediksi yang lebih bervariasi. Namun, penyebab biologis spesifik dari pola tersebut tidak dapat ditentukan berdasarkan dataset yang tersedia karena metadata mengenai umur tanaman, status air, kondisi kesehatan, pencahayaan, dan sesi akuisisi tidak terdokumentasi secara memadai. Oleh karena itu, pola *underestimation* pada 750 dan 1.000 ppm diperlakukan sebagai temuan empiris pada dataset penelitian ini dan tidak digunakan untuk menyimpulkan mekanisme fisiologis tertentu.

Perbedaan antara MAE sebesar 42,76 ppm dan RMSE sebesar 107,37 ppm menunjukkan adanya sejumlah prediksi dengan kesalahan relatif besar pada data uji. MAE menggambarkan rata-rata magnitudo kesalahan, sedangkan RMSE memberikan penalti lebih besar terhadap penyimpangan yang ekstrem. Perbedaan tersebut sejalan dengan peningkatan penyebaran prediksi pada tingkat perlakuan 750 dan 1.000 ppm, sehingga penggunaan kedua metrik secara bersamaan memberikan gambaran yang lebih lengkap mengenai karakteristik kesalahan model. Interval kepercayaan berbasis *bootstrap* juga menunjukkan bahwa estimasi performa memiliki ketidakpastian, sehingga nilai metrik sebaiknya tidak dipandang sebagai ukuran yang sepenuhnya bebas dari variasi sampel.

Hasil penelitian ini menunjukkan kinerja pipeline YOLOv8s-EfficientNetV2-S pada skema estimasi nilai perlakuan yang digunakan. Namun, interpretasi kinerja tersebut belum dapat dibandingkan secara langsung

dengan arsitektur deep learning lain karena penelitian ini belum melakukan pelatihan dan pengujian model pembandingan seperti MobileNetV3, ResNet50, atau EfficientNet-B0 pada dataset dan pembagian data yang sama. Demikian pula, pendekatan berbasis statistik warna maupun formulasi klasifikasi empat kelas belum dievaluasi secara eksperimental. Oleh karena itu, hasil yang diperoleh pada penelitian ini perlu dipahami sebagai kinerja dari pipeline yang dikembangkan, bukan sebagai bukti bahwa EfficientNetV2-S atau pendekatan regresi yang digunakan merupakan pilihan yang lebih unggul dibandingkan metode alternatif.

Interpretasi R^2 sebesar 0,8577 perlu mempertimbangkan struktur target penelitian yang hanya terdiri atas empat tingkat perlakuan, yaitu 250, 500, 750, dan 1.000 ppm. Meskipun EfficientNetV2-S menghasilkan keluaran numerik, data pengujian tidak mencakup tingkat konsentrasi baru yang tidak digunakan selama pengembangan model. Oleh karena itu, nilai R^2 tersebut lebih tepat dipahami sebagai ukuran kesesuaian antara prediksi dan nilai perlakuan referensi yang tersedia dalam skema pengujian, bukan sebagai bukti bahwa model telah memiliki kemampuan kalibrasi kontinu atau interpolasi yang tervalidasi pada konsentrasi yang belum diamati. Formulasi regresi dipilih karena keluaran penelitian dinyatakan dalam satuan ppm sehingga kesalahan numerik antar tingkat perlakuan dapat dihitung secara langsung. Namun, karena hanya empat tingkat perlakuan yang tersedia, formulasi klasifikasi empat kelas atau klasifikasi ordinal tetap merupakan alternatif metodologis yang relevan dan belum diuji dalam penelitian ini.

Penggunaan YOLOv8s sebelum EfficientNetV2-S dirancang untuk membatasi informasi yang diteruskan ke model regresi pada wilayah daun yang menjadi objek analisis. Pendekatan ini memberikan mekanisme penyaringan spasial (*spatial filtering*) sehingga EfficientNetV2-S menerima representasi daun yang telah dilokalisasi, bukan keseluruhan citra beserta latar belakangnya. Secara metodologis, rancangan tersebut memberikan pemisahan fungsi antara tahap lokalisasi dan tahap estimasi, tetapi keunggulannya terhadap alternatif masukan belum dapat dipastikan. Penelitian ini belum melakukan *ablation study* yang membandingkan citra penuh, RoI berdasarkan anotasi *ground truth*, dan RoI hasil YOLOv8s, sehingga belum terdapat bukti eksperimental yang cukup untuk menyatakan bahwa konfigurasi *detector-guided* RoI merupakan konfigurasi yang paling optimal.

Selain rancangan model, faktor biologis dan lingkungan juga perlu dipertimbangkan dalam menafsirkan hasil. Umur tanaman, tahap

perkembangan, status air, kondisi kesehatan, suhu, pencahayaan, serta karakteristik kamera dapat memengaruhi tampilan visual daun dan berpotensi membentuk pola yang dipelajari oleh model. Dataset yang tersedia belum memiliki metadata tanaman, kelompok tanaman, *batch*, dan sesi akuisisi yang memadai untuk memisahkan pengaruh faktor-faktor tersebut atau menerapkan pembagian data berbasis kelompok (*group-aware split*). Dengan demikian, hasil penelitian ini belum dapat digeneralisasikan secara langsung terhadap tanaman, kondisi budidaya, perangkat kamera, atau sesi akuisisi yang berbeda dari konteks yang direpresentasikan dalam dataset.

Keterbatasan validasi juga berkaitan dengan belum tersedianya tingkat konsentrasi tambahan di luar empat tingkat perlakuan yang digunakan. Seluruh data yang tersedia hanya mencakup 250, 500, 750, dan 1.000 ppm sehingga kemampuan model pada konsentrasi yang tidak pernah diamati selama pengembangan belum dapat dinilai. Oleh sebab itu, hasil penelitian saat ini sebaiknya diposisikan sebagai evaluasi *detector-guided regression* pada empat tingkat perlakuan yang tersedia, bukan sebagai bukti bahwa sistem mampu melakukan estimasi kontinu pada rentang konsentrasi yang lebih luas. Berdasarkan temuan tersebut, pengembangan penelitian selanjutnya perlu diarahkan pada validasi yang dapat memisahkan pengaruh pembagian data, representasi citra, dan pemilihan model. *Ablation study* antara citra penuh, RoI *ground truth*, dan RoI hasil YOLOv8s dapat digunakan untuk menguji kontribusi tahap lokalisasi secara langsung, sedangkan penggunaan beberapa model *baseline* dapat memberikan konteks yang lebih objektif terhadap kinerja *EfficientNetV2-S*. Penambahan tingkat perlakuan di luar empat nilai yang tersedia, penerapan *group-aware split*, serta pencatatan metadata tanaman, *batch*, dan sesi akuisisi juga diperlukan untuk menguji kemampuan generalisasi secara lebih ketat. Perluasan kondisi pengambilan citra selanjutnya dapat digunakan untuk mengevaluasi ketahanan sistem terhadap variasi lingkungan dan perangkat yang lebih beragam.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Penelitian ini menghasilkan alur sistem berbasis citra yang menggabungkan YOLOv8s sebagai detektor daun dan *EfficientNetV2-S* sebagai regresor tingkat perlakuan konsentrasi larutan nutrisi pada pakcoy. Setelah audit dan deduplikasi, sebanyak 1.995 pasangan citra-label unik digunakan dengan pembagian 1.595 citra pelatihan, 200 citra validasi, dan

200 citra uji independen. Pada data uji, YOLOv8s memperoleh *precision* 0,9173, *recall* 0,8870, mAP@0,50 sebesar 0,9598, dan mAP@0,50:0,95 sebesar 0,8428. Sebanyak 170 dari 200 citra menghasilkan RoI yang dapat diproses pada tahap regresi. Pada 170 RoI tersebut, *EfficientNetV2-S* memperoleh MAE 42,76 ppm, RMSE 107,37 ppm, MAPE 5,71%, dan R^2 0,8577. Hasil ini menunjukkan kelayakan pendekatan estimasi berbasis detektor (*detector-guided estimation*) untuk empat tingkat perlakuan yang tersedia, tetapi belum membuktikan generalisasi pada konsentrasi yang belum diamati maupun kondisi budidaya yang berbeda.

5.2. Saran

- Penelitian selanjutnya disarankan menggunakan pembagian data berbasis kelompok tanaman, *batch*, atau sesi akuisisi apabila metadata *underestimation* tersedia, sehingga risiko korelasi antar-citra dari objek yang sama dapat dievaluasi dengan lebih ketat.
- Evaluasi komparatif juga perlu dilakukan melalui *ablation* antara citra penuh, RoI dari anotasi *ground truth*, dan RoI hasil YOLOv8s, serta perbandingan dengan beberapa model regresi dan klasifikasi sebagai *baseline*.
- Selain itu, penambahan tingkat konsentrasi di luar empat nilai yang digunakan saat ini, variasi kondisi akuisisi, dan pencatatan metadata eksperimen yang lebih lengkap diperlukan untuk menguji kemampuan generalisasi model.

DAFTAR PUSTAKA

- [1] L. Chang, X. Xiong, M. K. Hameed, D. Huang, and Q. Niu, "Study on nitrogen demand model in pakchoi (*Brassica campestris* ssp. *Chinensis* L.) based on nitrogen contents and phenotypic characteristics," *Front. Plant Sci.*, vol. 14, Feb. 2023, doi: 10.3389/fpls.2023.1111216.
- [2] E. Fathidarehnejeh, M. Nadeem, M. Cheema, R. Thomas, M. Krishnapillai, and L. Galagedara, "Current perspective on nutrient solution management strategies to improve the nutrient and water use efficiency in hydroponic systems," *Can. J. Plant Sci.*, vol. 104, no. 2, pp. 88–102, Apr. 2024, doi: 10.1139/cjps-2023-0034.
- [3] H. You, M. Zhou, J. Zhang, W. Peng, and C. Sun, "Sugarcane nitrogen nutrition estimation with digital images and machine learning methods," *Sci. Rep.*, vol. 13, no. 1, p. 14939, Sep. 2023, doi: 10.1038/s41598-023-42190-2.
- [4] H. Ge *et al.*, "Estimating Plant Nitrogen Concentration

- of Rice through Fusing Vegetation Indices and Color Moments Derived from UAV-RGB Images,” *Remote Sens.*, vol. 13, no. 9, p. 1620, Apr. 2021, doi: 10.3390/rs13091620.
- [5] Z. Qiu, F. Ma, Z. Li, X. Xu, H. Ge, and C. Du, “Estimation of nitrogen nutrition index in rice from UAV RGB images coupled with machine learning algorithms,” *Comput. Electron. Agric.*, vol. 189, p. 106421, Oct. 2021, doi: 10.1016/j.compag.2021.106421.
- [6] P. Shi *et al.*, “Rice nitrogen nutrition estimation with RGB images and machine learning methods,” *Comput. Electron. Agric.*, vol. 180, p. 105860, Jan. 2021, doi: 10.1016/j.compag.2020.105860.
- [7] I. Rosyidah, I. Anshory, I. Sulistiyowati, and S. Syahririni, “Implementation of Image Processing On Hydroponic Pakcoy Plants To Detect AB MIX Nutrient Levels,” *Jambura J. Electr. Electron. Eng.*, vol. 6, no. 2, pp. 234–239, Jul. 2024, doi: 10.37905/jjee.v6i2.26143.
- [8] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [9] M. Jeong *et al.*, “Rapid detection of soybean nutrient deficiencies with YOLOv8s for precision agriculture advancement,” *Sci. Rep.*, vol. 15, no. 1, p. 13810, Apr. 2025, doi: 10.1038/s41598-024-83295-6.
- [10] M. Hussain, “YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection,” *Machines*, vol. 11, no. 7, p. 677, Jun. 2023, doi: 10.3390/machines11070677.
- [11] M. Tan and Q. V Le, “EfficientNetV2: Smaller Models and Faster Training,” 2021. [Online]. Available: <https://github.com/google/>
- [12] M. Ahsan, S. Eshkabilov, B. Cemek, E. Küçüktopcu, C. W. Lee, and H. Simsek, “Deep Learning Models to Determine Nutrient Concentration in Hydroponically Grown Lettuce Cultivars (*Lactuca sativa* L.),” *Sustainability*, vol. 14, no. 1, p. 416, Dec. 2021, doi: 10.3390/su14010416.
- [13] L. A. Wardani, G. Pasek, S. Wijaya, and F. Bimantoro, “KLASIFIKASI JENIS DAN TINGKAT KEMATANGAN BUAH PEPAYA BERDASARKAN FITUR WARNA, TEKSTUR DAN BENTUK MENGGUNAKAN SUPPORT VECTOR MACHINE (Classification of Types and Levels of Ripeness of Papaya Fruit Based on Color, Texture and Shape Features Using Support Vector Machine).” [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- [14] R. S. Sandhya Devi, V. R. Vijay Kumar, and P. Sivakumar, “EfficientNetV2 Model for Plant Disease Classification and Pest Recognition,” *Comput. Syst. Sci. Eng.*, vol. 45, no. 2, pp. 2249–2263, 2023, doi: 10.32604/csse.2023.032231.
- [15] H. Rasyidah, J. T. Produksi, and D. Industri, “DETEKSI DEFISIENSI NUTRISI TANAMAN PAKCOY BERDASARKAN CITRA WARNA DAUN MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK TUGAS AKHIR PROGRAM STUDI TEKNIK FISIKA,” 2023.
- [16] Nisa, “dataset-pakcoy,” 2026, *GitHub*. [Online]. Available: <https://github.com/nisa2701/dataset-pakcoy>. [Accessed: 18 September 2026].