



Evaluasi Komparatif YOLOv8s dan YOLOv8s dengan *Slicing Aided Hyper Inference* untuk Deteksi Koloni Bakteri pada Citra Cawan Petri

Safrizal Razali^{*1}, Nurmalia Zakaria²

¹Departemen Teknik Elektro dan Komputer Universitas Syiah Kuala, ²Akademi Analis Farmasi dan Makanan Banda Aceh

*Email korespondensi : safrizal.razali@usk.ac.id

ABSTRAK

Deteksi dan kuantifikasi koloni bakteri merupakan proses penting dalam berbagai bidang, seperti mikrobiologi klinis, industri farmasi, keamanan pangan, dan penelitian biomedis. Metode penghitungan manual yang masih banyak digunakan memiliki keterbatasan berupa waktu pengerjaan yang lama, potensi kesalahan manusia, serta rendahnya konsistensi hasil. Penelitian ini bertujuan membandingkan kinerja deteksi koloni bakteri menggunakan model YOLOv8s Standar dan YOLOv8s yang dipadukan dengan *Slicing Aided Hyper Inference* (SAHI). Dataset yang digunakan adalah *colony_counter3* yang diunduh dari *Roboflow Universe* yang terdiri atas 4.624 citra (gambar) cawan petri dengan pembagian data 70% untuk *training*, 15% untuk validasi, dan 15% untuk pengujian. Evaluasi dilakukan menggunakan metrik precision, recall, F1-score, mAP50, mAP50-95, waktu inferensi, dan throughput. Hasil penelitian menunjukkan bahwa YOLOv8s Standar memperoleh precision 96,79%, recall 93,02%, F1-score 94,87%, mAP50 85%, dan mAP50-95 62%, sedangkan YOLOv8s+SAHI memperoleh precision 48,19%, recall 18,62%, F1-score 26,86%, mAP50 92%, dan mAP50-95 71%. Meskipun YOLOv8s+SAHI meningkatkan kualitas lokalisasi objek yang ditunjukkan oleh kenaikan mAP50 dan mAP50-95, pendekatan model ini menghasilkan penurunan yang signifikan pada precision, recall, dan F1-score serta meningkatkan waktu inferensi dari 9,91 ms menjadi 35,59 ms per citra. Hasil penelitian menunjukkan bahwa penerapan YOLOv8s+SAHI tidak selalu memberikan peningkatan kinerja pada deteksi koloni bakteri dan efektivitasnya sangat dipengaruhi oleh karakteristik dataset. Untuk dataset yang digunakan dalam penelitian ini, YOLOv8s Standar terbukti lebih akurat dan efisien dibandingkan YOLOv8s+SAHI.

Kata kunci : YOLOv8s, SAHI, deteksi koloni bakteri, deteksi objek, *deep learning*.

ABSTRACT

Bacterial colony detection and quantification are essential processes in various fields, including clinical microbiology, the pharmaceutical industry, food safety, and biomedical research. Manual counting methods, which are still widely used, suffer from several limitations, such as time-consuming procedures, susceptibility to human error, and low consistency of results. This study aims to compare the performance of bacterial colony detection using standard YOLOv8s and YOLOv8s integrated with *Slicing Aided Hyper Inference* (SAHI). The dataset used was the *colony_counter3* dataset from *Roboflow Universe*, consisting of 4,624 petri dish images, with a data split of 70% for training, 15% for validation, and 15% for testing. Performance evaluation was conducted using precision, recall, F1-score, mAP50, mAP50-95, inference time, and throughput metrics. The results showed that standard YOLOv8s achieved a precision of 96.79%, recall of 93.02%, F1-score of 94.87%, mAP50 of 85%, and mAP50-95 of 62%, whereas YOLOv8s+SAHI achieved a precision of 48.19%, recall of 18.62%, F1-score of 26.86%, mAP50 of 92%, and mAP50-95 of 71%. Although YOLOv8s+SAHI improved object localization quality, as indicated by the higher mAP50 and mAP50-95 values, it resulted in a substantial decrease in precision, recall, and F1-score, while also increasing inference time from 9.91 ms to 35.59 ms per image. These findings indicate that the application of YOLOv8s+SAHI does not necessarily improve bacterial colony

detection performance and that its effectiveness is highly dependent on dataset characteristics. For the dataset used in this study, standard YOLOv8s proved to be more accurate and computationally efficient than YOLOv8s+SAHI.

Keyword: YOLOv8s, SAHI, bacterial colony detection, object detection, deep learning.

PENDAHULUAN

Deteksi dan kuantifikasi koloni bakteri pada cawan petri (*petri dish*) merupakan prosedur fundamental yang mendasari berbagai disiplin ilmu, meliputi mikrobiologi klinis untuk diagnosis infeksi (Tille, 2021), industri farmasi untuk uji sterilitas dan stabilitas biologi sediaan (Kemenkes RI, 2020), keamanan pangan untuk deteksi kontaminasi patogen dan efektivitas pengawet (Mendonça et al., 2014), serta penelitian biomedis untuk studi pertumbuhan, aktivitas antibakteri dari obat alam, dan resistensi mikroba (Cappuccino, 2019). Metode konvensional yang mengandalkan penghitungan manual oleh teknisi laboratorium terlatih seperti *colony-forming unit* (CFU) *counting* telah digunakan selama lebih dari satu abad. Namun, pendekatan ini memiliki keterbatasan fundamental yang semakin terasa di era *high-throughput screening* yaitu kelelahan visual operator setelah pemeriksaan dalam jumlah besar, variabilitas antar-pengamat yang signifikan mencapai 15-25% (Jung & Lee, 2016), inkonsistensi hasil, serta rendemen rendah ketika berhadapan dengan kepadatan koloni tinggi atau tumpang tindih.

Selama dekade terakhir, *deep learning* telah muncul sebagai paradigma dominan untuk otomatisasi analisis citra (gambar) biologis (da Silva et al., 2023). Arsitektur deteksi objek berbasis *convolutional neural network* (CNN) seperti Faster R-CNN (Ren et al., 2016), *Single Shot MultiBox Detector* (SSD) (Liu et al., 2016), dan khususnya keluarga *You Only Look Once* (YOLO) (Redmon et al., 2016) telah menunjukkan kinerja impresif dalam berbagai aplikasi visi komputer. YOLO membedakan diri melalui pendekatan *single-stage detection* yang memproses seluruh citra dalam satu kali *forward pass*, menawarkan keseimbangan optimal antara akurasi dan kecepatan inferensi.

YOLOv8, yang dirilis oleh Ultralytics pada awal 2023, merupakan iterasi terbaru dari keluarga YOLO yang memperkenalkan sejumlah inovasi arsitektural signifikan: CSPDarknet backbone dengan C2f module untuk efisiensi aliran gradien, *anchor-free detection head* yang menyederhanakan prediksi, serta integrasi berbagai teknik augmentasi data canggih (Jocher et al., 2023). Arsitektur ini menawarkan lima varian skala (nano hingga extra-large), memungkinkan penyesuaian berdasarkan ketersediaan sumber daya komputasi dan kompleksitas tugas. Dalam konteks mikrobiologi, beberapa studi awal telah mengeksplorasi YOLOv8 untuk deteksi koloni (Wang et al., 2025), meskipun umumnya masih terbatas pada dataset yang relatif kecil dan kondisi laboratorium yang terkontrol.

Meskipun YOLOv8 menunjukkan performa yang sangat baik dalam berbagai tugas deteksi objek, deteksi objek berukuran kecil masih menjadi tantangan utama dalam computer vision. Pada citra cawan petri, koloni bakteri sering kali memiliki ukuran relatif kecil, tumbuh berdekatan, dan saling tumpang tindih sehingga menyulitkan proses deteksi otomatis. Selain itu, proses *downsampling* citra yang umum dilakukan pada model deteksi objek dapat menyebabkan hilangnya informasi visual penting yang dibutuhkan untuk mengidentifikasi koloni berukuran kecil.

Salah satu pendekatan yang dikembangkan untuk mengatasi permasalahan tersebut adalah *Slicing Aided Hyper Inference* (SAHI) (Akyon et al., 2022). Metode ini bekerja dengan membagi citra beresolusi tinggi menjadi beberapa potongan (*slice*) yang saling tumpang tindih, kemudian melakukan deteksi pada setiap potongan secara terpisah sebelum hasilnya digabungkan kembali. Pendekatan ini memungkinkan objek kecil tetap diproses pada resolusi yang lebih tinggi sehingga berpotensi meningkatkan akurasi deteksi.

Berbagai penelitian telah menunjukkan efektivitas SAHI pada domain deteksi objek kecil, seperti citra udara, deteksi cacat permukaan, dan pengawasan maritim. Beberapa


studi terbaru juga melaporkan hasil yang menjanjikan pada deteksi koloni bakteri. Namun demikian, sebagian besar penelitian hanya melaporkan performa akhir tanpa melakukan perbandingan langsung dengan model dasar (*baseline*), sehingga kontribusi nyata SAHI terhadap peningkatan kinerja belum dapat dievaluasi secara komprehensif. Selain itu, kajian mengenai *trade-off* antara peningkatan akurasi dan biaya komputasi yang ditimbulkan oleh SAHI masih relatif terbatas.

Berdasarkan kondisi tersebut, penelitian ini bertujuan membandingkan kinerja deteksi koloni bakteri menggunakan YOLOv8s standar dan YOLOv8s yang dipadukan dengan SAHI pada citra cawan petri beresolusi tinggi. Evaluasi dilakukan menggunakan metrik *precision*, *recall*, *F1-score*, *mAP50*, *mAP50-95*, serta waktu inferensi. Hasil penelitian diharapkan dapat memberikan bukti empiris mengenai efektivitas YOLOv8s+SAHI pada deteksi koloni bakteri sekaligus menjadi referensi dalam pemilihan metode yang sesuai berdasarkan kebutuhan akurasi dan efisiensi komputasi.

METODE PENELITIAN

Desain Penelitian

Penelitian ini menggunakan desain *comparative experimental study* untuk mengevaluasi kinerja dua pendekatan deteksi objek berbasis deep learning pada tugas identifikasi koloni bakteri. Pendekatan yang dibandingkan adalah (1) YOLOv8s standar (*baseline*) dan (2) YOLOv8s dengan *Slicing Aided Hyper Inference* (SAHI) (*treatment*). Seluruh eksperimen dijalankan pada dataset yang identik dengan protokol evaluasi yang konsisten, memungkinkan isolasi efek perlakuan (SAHI) terhadap variabel dependen (metrik kinerja deteksi).



Gambar 1. Diagram alir metodologi penelitian

Desain penelitian mengadopsi protokol *cross-validation* dengan *fixed split* (70% training, 15% validation, 15% test) yang telah ditetapkan oleh penyedia dataset. Tidak dilakukan data leakage antara split training, validation, dan test. Setiap model dilatih dari awal (*trained from scratch*) dengan bobot pretrained ImageNet/MS COCO sebagai inisialisasi (*transfer learning*), kemudian dievaluasi pada test set yang sama untuk kedua pendekatan. Gambar 2.1 menyajikan diagram alir metodologi penelitian secara keseluruhan, yang mencakup tiga fase utama: (1) persiapan dan pra-pemrosesan data, (2) pelatihan model, dan (3) evaluasi komparatif.

Dataset

Dataset yang digunakan dalam penelitian ini diunduh dari *Roboflow Universe* (colony_counter3 project, versi 3, tiling-beta). *Roboflow Universe* merupakan *platform open-source* untuk dataset visi komputer yang banyak digunakan dalam penelitian deep learning. Dataset ini berisi citra cawan petri yang diambil dalam berbagai kondisi pencahayaan dan kepadatan koloni, mencerminkan variasi dunia nyata yang ditemui di laboratorium mikrobiologi. Karakteristik utama dataset disajikan pada Tabel 1.

Tabel 1. Karakteristik Dataset colony_counter3.v3-tiling-beta

No.	Nama	Keterangan
1	Parameter	Spesifikasi
2	Total citra	4,624
3	Split (train:valid:test)	3,237 : 693 : 694
4	Rasio split	70% : 15% : 15%
5	Resolusi asli sebelum pre-processing	Bervariasi (tidak dispesifikasi)
6	Resolusi setelah pre-processing	960 × 960 piksel (stretch)
7	Format anotasi	YOLOv8 (format teks)
8	Jumlah kelas	2
9	Nama kelas	['colony', 'petri_dish']
10	Pre-processing yang diterapkan	Auto-orientation, resize to 960×960 (stretch)
11	Augmentasi yang diterapkan	Tidak ada

Dataset ini dipilih karena beberapa alasan: (1) ukurannya yang memadai untuk training deep learning ($n > 4,000$ citra), (2) kualitas anotasi yang terjamin melalui platform Roboflow, (3) representasi variasi koloni yang realistis, dan (4) ketersediaan public untuk replikasi penelitian. Citra dataset ini dilakukan rotasi otomatis berdasarkan metadata EXIF untuk memastikan orientasi citra yang konsisten. Semua citra diubah ukurannya menjadi 960×960 piksel dengan metode stretch (tanpa menjaga aspek rasio). Dalam penelitian ini, augmentasi data diterapkan hanya pada fase training (bukan pada validation/test set) menggunakan parameter yang dikonfigurasi melalui Ultralytics YOLOv8 seperti yang terlihat pada Gambar 1.

HASIL DAN PEMBAHASAN

Gambaran Umum Eksperimen

Eksperimen komparatif antara YOLOv8s Standard dan YOLOv8s+SAHI dilakukan pada dataset colony_counter3 (*Roboflow Universe*) yang terdiri dari 4,624 citra cawan petri. Dataset dibagi menjadi tiga subset: training (70%, $n=3,237$), validasi (15%, $n=693$), dan test (15%, $n=694$). Total anotasi ground truth pada test set adalah 3,567 koloni yang tersebar pada 694 citra. Tabel 2 menyajikan ringkasan dataset dan konfigurasi eksperimen.

Tabel 2. Ringkasan Dataset dan Konfigurasi Eksperimen

No.	Parameter	Nilai
1	Total citra	4,624
2	Split (train:val:test)	70% : 15% : 15%
3	Resolusi citra	960 × 960 piksel
4	Total ground truth (test set)	3,567 koloni
5	Rata-rata koloni per citra	5.14
6	Kelas	'colony', 'petri_dish'
7	Model arsitektur	YOLOv8s (small)
8	Epochs	100
9	Batch size	16
10	GPU	NVIDIA RTX 5060 Ti (16 GB)

Hasil Evaluasi Kuantitatif

Evaluasi kuantitatif dilakukan terhadap 694 citra uji untuk membandingkan kinerja model YOLOv8s standar dan YOLOv8s+SAHI. Analisis difokuskan pada metrik deteksi objek yang umum digunakan, yaitu precision, recall, F1-score, mAP50, mAP50-95, waktu inferensi, dan throughput. Selain itu, dilakukan evaluasi terhadap jumlah deteksi aktual yang dihasilkan model melalui perhitungan true positives (TP), false positives (FP), dan false negatives (FN). Hasil evaluasi menunjukkan adanya perbedaan karakteristik kinerja yang cukup signifikan antara kedua pendekatan.

Tabel 2 menyajikan perbandingan kinerja kedua model berdasarkan metrik evaluasi utama. Secara umum, penerapan YOLOv8s+SAHI menghasilkan peningkatan pada metrik mAP50 dan mAP50-95, yang mengindikasikan perbaikan kualitas lokalisasi objek. Namun, peningkatan tersebut disertai penurunan yang cukup besar pada precision, recall, dan F1-score serta peningkatan waktu inferensi. Temuan ini menunjukkan adanya trade-off antara kualitas deteksi dan efisiensi komputasi ketika YOLOv8s+SAHI diterapkan pada dataset koloni bakteri yang digunakan dalam penelitian ini.


Tabel 3. Perbandingan Kinerja YOLOv8s Standard vs YOLOv8s+SAHI

Metrik	YOLOv8s Standard	YOLOv8s+SAHI	Perubahan Absolut	Perubahan Relatif
Precision	96.79%	48.19%	-48,60%	-50.2%
Recall	93.02%	18.62%	-74/40%	-80.0%
F1-Score	94.87%	26.86%	-68.01%	-71.7%
mAP50	85.00%	92.00%	+07.00%	+8.2%
mAP50-95	62.00%	71.00%	+09.00%	+14.5%
Inference Time	9.91 ms	35.59 ms	+25.68 ms	+259%
Throughput	101 img/s	28 img/s	-73 img/s	-72.3%

Untuk memberikan gambaran yang lebih rinci mengenai sumber perbedaan kinerja tersebut, Tabel 4 menyajikan jumlah deteksi dalam bentuk absolut, meliputi true positives (TP), false positives (FP), false negatives (FN), total deteksi yang dihasilkan model, dan jumlah *ground truth*. Data ini memungkinkan analisis yang lebih mendalam mengenai kemampuan masing-masing model dalam menemukan koloni bakteri yang sebenarnya serta kecenderungan menghasilkan kesalahan deteksi.

Tabel 4. Rincian Deteksi dalam Angka Absolut

Komponen	YOLOv8s Standard	YOLOv8s+SAHI	Perbedaan
True Positives (TP)	3,318	664	-2,654
False Positives (FP)	110	714	+604
False Negatives (FN)	249	2,903	+2,654
Total Detections	3,428	1,378	-2,050
Ground Truth (GT)	3,567	3,567	0



Gambar 2. Confusion matrix YOLOv8s Standard Vs YOLOv8s+SAHI

Analisis Kinerja per Metrik

Hasil evaluasi menunjukkan bahwa YOLOv8s Standard secara konsisten memberikan kinerja yang lebih baik dibandingkan YOLOv8s+SAHI pada metrik precision, recall, dan F1-score. Model YOLOv8s Standard menghasilkan precision sebesar 96,79%, recall 93,02%, dan F1-score 94,87%, yang menunjukkan kemampuan sangat baik dalam mendeteksi koloni bakteri dengan tingkat keberhasilan yang cukup tinggi dan kesalahan yang rendah. Sebaliknya, penerapan YOLOv8s+SAHI menghasilkan penurunan deteksi jumlah koloni yang signifikan pada seluruh metrik tersebut, dengan precision 48,19%, recall 18,62%, dan F1-score 26,86%. Nilai recall yang sangat rendah mengindikasikan bahwa sebagian besar koloni gagal terdeteksi, ditunjukkan oleh tingginya jumlah *false negative* (2.903 koloni) dibandingkan model YOLOv8s Standard yang hanya menghasilkan 249 *false negative*. Kondisi ini menunjukkan bahwa pendekatan YOLOv8s+SAHI pada konfigurasi yang digunakan belum mampu mempertahankan sensitivitas deteksi yang dibutuhkan untuk tugas penghitungan koloni bakteri.

Meskipun demikian, hasil yang menarik terlihat pada metrik mAP50 dan mAP50-95. YOLOv8s+SAHI memperoleh mAP50 sebesar 92% dan mAP50-95 sebesar 71%, lebih tinggi dibandingkan YOLOv8s Standard yang masing-masing mencapai 85% dan 62%. Peningkatan ini menunjukkan bahwa ketika objek citra koloni bakteri berhasil terdeteksi, kualitas lokalisasi *bounding box* yang dihasilkan SAHI cenderung lebih baik. Namun, peningkatan mAP tersebut tidak sejalan dengan penurunan drastis pada precision dan recall. Fenomena ini mengindikasikan bahwa model YOLOv8s+SAHI mampu menghasilkan prediksi dengan posisi *bounding box* yang lebih akurat pada sebagian objek, tetapi gagal mendeteksi sebagian besar koloni yang sebenarnya ada. Untuk aplikasi penghitungan koloni bakteri, kondisi tersebut menjadi kelemahan yang sangat penting karena jumlah koloni yang tidak terdeteksi jumlahnya jauh lebih banyak dibandingkan peningkatan akurasi lokalisasi pada objek yang berhasil terdeteksi.

Dari sisi efisiensi komputasi, YOLOv8s Standard juga menunjukkan performa yang lebih unggul. Waktu inferensi rata-rata model standar hanya 9,91 ms per citra dengan *throughput* mencapai 101 citra per detik, sedangkan YOLOv8s+SAHI memerlukan 35,59 ms per citra dengan *throughput* 28 citra per detik. Dengan kata lain, penggunaan YOLOv8s+SAHI menyebabkan proses inferensi menjadi sekitar 3,6 kali lebih lambat dibandingkan pendekatan YOLOv8s Standard. Kombinasi antara penurunan akurasi deteksi dan peningkatan biaya komputasi menunjukkan bahwa penerapan YOLOv8s+SAHI pada dataset koloni bakteri dalam penelitian awal ini belum menunjukkan hasil yang memuaskan.

Pembahasan

Hasil penelitian menunjukkan bahwa penerapan YOLOv8s+SAHI pada deteksi koloni bakteri tidak memberikan peningkatan kinerja secara keseluruhan dibandingkan YOLOv8s standar. Meskipun nilai mAP50 dan mAP50-95 meningkat, penurunan yang sangat signifikan pada precision, recall, dan F1-score mengindikasikan bahwa pendekatan ini kurang sesuai untuk karakteristik dataset yang digunakan. Temuan ini berbeda dengan beberapa penelitian sebelumnya yang melaporkan keberhasilan YOLOv8s+SAHI dalam meningkatkan deteksi objek kecil pada citra udara, pengawasan maritim, maupun deteksi cacat permukaan (Akyon et al., 2022). Perbedaan hasil tersebut menguatkan pendapat bahwa efektivitas YOLOv8s+SAHI sangat bergantung pada karakteristik objek, konfigurasi pelatihan, serta kesesuaian parameter *slicing* yang digunakan pada setiap domain aplikasi.

Salah satu faktor utama yang diduga menyebabkan rendahnya performa YOLOv8s+SAHI adalah ketidakkonsistenan antara proses *training* dan inferensi. Model YOLOv8s standar dilatih dan diuji pada resolusi yang sama, yaitu 960×960 piksel, sehingga distribusi ukuran objek yang dipelajari selama *training* tetap terjaga saat inferensi. Sebaliknya, model YOLOv8s+SAHI dilatih menggunakan citra berukuran 640×640 piksel,

tetapi pada tahap inferensi menerima potongan (*slice*) dari citra dengan resolusi yang lebih tinggi. Perbedaan distribusi ukuran objek ini berpotensi menyebabkan pergeseran domain (*domain shift*) sehingga model mengalami kesulitan mengenali pola objek secara konsisten. Selain itu, konfigurasi *training* YOLOv8s+SAHI pada penelitian ini menonaktifkan *mosaic augmentation* yang merupakan salah satu teknik augmentasi penting dalam YOLOv8 untuk meningkatkan variasi konteks dan skala objek. Hilangnya augmentasi tersebut diduga mengurangi kemampuan generalisasi model terhadap variasi kondisi citra yang ditemukan pada data uji.

Faktor lain yang turut berkontribusi adalah mekanisme *slicing* itu sendiri. Penggunaan overlap sebesar 20% memungkinkan objek yang berada di area perbatasan koloni terdeteksi lebih dari satu kali pada beberapa *slice* yang berbeda. Walaupun proses *Non-Maximum Suppression* (NMS) diterapkan untuk menghilangkan deteksi ganda, hasil eksperimen menunjukkan peningkatan jumlah *false positive* yang cukup besar pada model YOLOv8s+SAHI. Kondisi ini mengindikasikan bahwa sebagian deteksi duplikat tidak berhasil dieliminasi secara optimal. Di samping itu, karakteristik dataset koloni bakteri yang digunakan tampaknya tidak sepenuhnya memenuhi skenario ideal penggunaan YOLOv8s+SAHI. Sebagian besar koloni memiliki ukuran yang relatif besar setelah proses *resize* dan memiliki kontras yang jelas terhadap latar belakang, sehingga objek dapat dideteksi dengan baik oleh YOLOv8 Standar tanpa memerlukan proses *slicing* tambahan. Dengan demikian, *overhead* komputasi yang ditimbulkan oleh YOLOv8s+SAHI tidak sebanding dengan manfaat yang diperoleh. Temuan ini menunjukkan bahwa YOLOv8s+SAHI lebih tepat diterapkan pada kasus deteksi objek yang benar-benar berukuran sangat kecil dan sulit dikenali pada citra resolusi tinggi, sedangkan untuk dataset koloni bakteri pada penelitian ini, pendekatan YOLOv8s Standar merupakan pilihan yang lebih efektif dan efisien.

KESIMPULAN DAN SARAN

Penelitian ini telah membandingkan kinerja YOLOv8s Standar dan YOLOv8s yang dipadukan dengan *Slicing Aided Hyper Inference* (SAHI) untuk deteksi koloni bakteri pada dataset *colony_counter3* yang terdiri atas 4.624 citra cawan petri. Hasil eksperimen menunjukkan bahwa YOLOv8s standar memberikan performa yang lebih baik pada sebagian besar metrik evaluasi utama, yaitu *precision* sebesar 96,79%, *recall* 93,02%, dan *F1-score* 94,87%. Sebaliknya, YOLOv8s+SAHI hanya memperoleh *precision* 48,19%, *recall* 18,62%, dan *F1-score* 26,86%, yang menunjukkan penurunan kemampuan deteksi yang sangat signifikan. Dari sisi efisiensi komputasi, YOLOv8s Standar juga lebih unggul dengan waktu inferensi rata-rata 9,91 ms per citra dan *throughput* 101 citra per detik, sedangkan YOLOv8s+SAHI memerlukan 35,59 ms per citra dengan *throughput* 28 citra per detik. Meskipun demikian, penerapan SAHI menghasilkan peningkatan pada metrik *mAP50* dari 85% menjadi 92% dan *mAP50-95* dari 62% menjadi 71%, yang menunjukkan bahwa kualitas lokalisasi *bounding box* meningkat ketika objek berhasil terdeteksi. Namun, peningkatan tersebut tidak mampu mengimbangi penurunan drastis pada *precision*, *recall*, dan *F1-score* sehingga secara keseluruhan pendekatan YOLOv8s+SAHI tidak memberikan keuntungan praktis untuk tugas penghitungan koloni bakteri pada dataset yang digunakan. Temuan ini menunjukkan bahwa efektivitas YOLOv8s+SAHI sangat dipengaruhi oleh karakteristik dataset dan tidak selalu menghasilkan peningkatan performa pada semua kasus deteksi objek.

Berdasarkan hasil penelitian, penggunaan YOLOv8s Standar direkomendasikan untuk deteksi koloni bakteri pada citra cawan petri karena memberikan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi. Untuk penelitian selanjutnya, perlu dilakukan eksplorasi lebih lanjut terhadap konfigurasi YOLOv8s+SAHI, seperti ukuran *slice*, rasio overlap, dan parameter pascaproses, guna memperoleh kombinasi yang lebih sesuai dengan karakteristik objek yang dideteksi. Selain itu, pengujian pada dataset dengan objek yang lebih kecil, kepadatan koloni yang lebih tinggi, atau resolusi citra yang lebih besar perlu

dilakukan untuk mengevaluasi kondisi ideal penerapan YOLOv8s+SAHI. Penelitian mendatang juga dapat membandingkan YOLOv8s+SAHI dengan pendekatan lain yang dirancang khusus untuk deteksi objek berukuran kecil, sehingga dapat diperoleh pemahaman yang lebih komprehensif mengenai strategi yang paling efektif untuk otomatisasi penghitungan koloni bakteri.

DAFTAR PUSTAKA

- Akyon, F. C., Altinuc, S. O., & Temizel, A. (2022). *Slicing Aided Hyper Inference and Fine-tuning for Small Object Detection*.
- Cappuccino, J. G. (2019). *Microbiology: A Laboratory Manual* (12th ed.). Pearson.
- da Silva, G. R., Rosmaninho, I. B., Zancul, E., de Oliveira, V. R., Francisco, G. R., dos Santos, N. F., de Mello Macêdo, K., da Silva, A. J., de Lima, É. K., Lemo, M. E. B., Maldonado, A., Moura, M. E. G., da Silva, F. H., & Guimarães, G. S. (2023). Image dataset of urine test results on petri dishes for deep learning classification. *Data in Brief*, 47.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8*. <https://github.com/ultralytics/ultralytics>
- Jung, J. H., & Lee, J. E. (2016). Real-time bacterial microcolony counting using on-chip microscopy. *Scientific Reports*, 6(1), 21473.
- Kemenkes RI. (2020). *Farmakope Indonesia* (VI). Kementerian Kesehatan RI.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). *SSD: Single Shot MultiBox Detector*.
- Mendonça, A. F., Juneja, V. K., & Daraba, A. (2014). TOTAL VIABLE COUNTS | Metabolic Activity Tests. In *Encyclopedia of Food Microbiology* (pp. 610–617). Elsevier.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*.
- Ren, S., He, K., Girshick, R., & Sun, J. (2016). *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*.
- Tille, P. M. (2021). *Bailey & Scott's Diagnostic Microbiology*. Elsevier Health Sciences.
- Wang, M., Luo, J., Lin, K., Chen, Y., Huang, X., Liu, J., Wang, A., & Xiao, D. (2025). Colony-YOLO: A Lightweight Micro-Colony Detection Network Based on Improved YOLOv8n. *Microorganisms*, 13(7), 1617.