

Pengembangan Otomasi Inventaris Farmasi Rumah Sakit Gigi dan Mulut Berbasis YOLO

Siti Salmiah*¹, Khairul Abdi²

Rumah Sakit Gigi dan Mulut Universitas Sumatera Utara

e-mail: *salmiadentist@yahoo.co.id, ²154khairulabdi@gmail.com

Abstrak

Pengelolaan inventaris farmasi pada Rumah Sakit Gigi dan Mulut (RSGM) membutuhkan akurasi tinggi karena berpengaruh langsung terhadap ketersediaan obat dan kelancaran pelayanan. Penelitian ini mengembangkan sistem deteksi objek untuk otomasi inventaris berbasis **Ultralytics YOLO11s** menggunakan dataset citra produk farmasi sebanyak **11 kelas**. Model dilatih selama **60 epoch** dengan ukuran citra **640×640** dan dievaluasi menggunakan metrik **precision**, **recall**, **mAP@0.5**, dan **mAP@0.5:0.95**. Hasil pengujian menunjukkan performa yang baik dengan **precision 0,93**, **recall 0,97**, **mAP@0,5 0,98**, dan **mAP@0,5:0,95 0,90**, sehingga berpotensi membantu proses stock-taking lebih cepat dan konsisten. **Kebaruan (novelty)** penelitian ini terletak pada penerapan model YOLO generasi terbaru (YOLO11s) yang ringan untuk **multi-kelas produk farmasi RSGM** serta penyajian evaluasi komprehensif (kurva pelatihan, confusion matrix, dan contoh inferensi) sebagai dasar implementasi audit stok berbasis citra. **Keterbatasan** penelitian ini adalah ukuran dataset yang relatif terbatas dan akuisisi citra pada kondisi lingkungan tertentu, sehingga generalisasi pada variasi pencahayaan, sudut pengambilan, dan latar belakang yang lebih beragam masih memerlukan validasi tambahan.

Kata kunci— inventaris farmasi, deteksi objek, YOLO

Abstract

Pharmacy inventory management in a dental and oral hospital requires high accuracy because it directly affects drug availability and service continuity. This study develops an object-detection approach for automated inventory using **Ultralytics YOLO11s** and a custom image dataset consisting of **11 pharmacy product classes**. The model was fine-tuned for **60 epochs** with an image size of **640×640** and evaluated using **precision**, **recall**, **mAP@0.5**, and **mAP@0.5:0.95**. The results indicate strong performance with **0.93 precision**, **0.97 recall**, **0.98 mAP@0.5**, and **0.90 mAP@0.5:0.95**, showing the potential to support faster and more consistent stock auditing. The **novelty** of this work lies in tailoring a lightweight, recent YOLO variant (YOLO11s) to multi-class **RSGM pharmacy items** and presenting an end-to-end workflow supported by comprehensive evaluation (training curves, confusion matrix, and inference examples). **Limitations** include the relatively small dataset and image acquisition under a limited setting; therefore, broader generalization and real-time deployment should be validated using more diverse data and external testing.

Keywords— pharmacy inventory, object detection, YOLO

PENDAHULUAN

Manajemen inventaris pada gudang farmasi rumah sakit gigi dan mulut membutuhkan pencatatan yang akurat, cepat, dan konsisten untuk menjaga ketersediaan obat dan bahan selama pelayanan klinis. Proses manual seperti pencatatan kartu stok, rekap harian, dan audit berkala berisiko menimbulkan kesalahan manusia, keterlambatan pembaruan data, serta ketidaksesuaian antara stok fisik dan catatan. Dampaknya dapat berupa stockout, overstock, dan meningkatnya risiko kedaluwarsa yang menurunkan efisiensi operasional.

Perkembangan visi komputer memungkinkan otomasi inventaris berbasis citra. Pada skenario rak atau gudang, deteksi objek lebih relevan dibanding klasifikasi gambar karena mampu melakukan identifikasi dan lokalisasi objek secara bersamaan pada satu citra. YOLO (You Only Look Once) banyak digunakan untuk deteksi objek karena inferensi yang cepat dan performa yang kompetitif, sehingga sesuai untuk kebutuhan inspeksi stok semi real-time.

Penelitian ini mengusulkan otomasi inventaris berbasis YOLO11s untuk mendeteksi dan menghitung produk farmasi multi-kelas. Tahapan penelitian meliputi penyusunan dataset, anotasi bounding box dalam format YOLO, pelatihan model dengan bobot pra-latih, serta evaluasi menggunakan precision, recall, F1-score, mAP@0.5, dan mAP@0.5:0.95. Kontribusi utama penelitian adalah menunjukkan kelayakan deteksi objek untuk mendukung inspeksi stok berbasis citra dengan performa tinggi pada dataset produk farmasi.

Pada instalasi farmasi Rumah Sakit Gigi dan Mulut (RSGM), proses inventaris (stock-taking) dan pemantauan ketersediaan produk harus dilakukan secara rutin untuk mencegah kekosongan stok dan mengurangi risiko keterlambatan pelayanan. Namun, stock-taking manual cenderung memakan waktu, rentan kesalahan pencatatan, serta sulit menjaga konsistensi ketika jumlah item banyak dan kemasan produk mirip.

Perkembangan computer vision, khususnya deteksi objek berbasis deep learning, membuka peluang otomasi inventaris melalui pengenalan dan penghitungan produk dari citra. Keluarga model YOLO berkembang pesat dari versi klasik hingga generasi terbaru seperti YOLOv7, YOLOv9, dan YOLOv10 yang meningkatkan akurasi dan efisiensi inferensi untuk skenario real-time. Penerapan YOLO pada pemantauan stok ritel (misalnya deteksi ketersediaan produk pada rak/OSA dan out-of-stock detection) telah menunjukkan hasil yang menjanjikan, termasuk pendekatan YOLOv7 untuk deteksi stok rak dan studi OOS berbasis deep learning pada citra rak.


Gap penelitian pada konteks farmasi RSGM masih nyata: (1) karakteristik produk farmasi memiliki kemasan yang sering serupa secara visual sehingga menantang model deteksi, (2) sebagian besar studi inventory berbasis vision fokus pada ritel umum, bukan inventaris produk farmasi rumah sakit, dan (3) evaluasi pada model YOLO generasi terbaru (mis. YOLO11) untuk kebutuhan audit stok berbasis citra di lingkungan RSGM masih terbatas. YOLO11 sendiri merupakan rilis Ultralytics yang menekankan akurasi dan efisiensi untuk berbagai tugas computer vision.

Berdasarkan gap tersebut, penelitian ini mengusulkan pengembangan sistem otomasi inventaris farmasi RSGM berbasis Ultralytics YOLO11s dengan penyusunan dataset multi-kelas dan evaluasi performa yang terukur. Kontribusi penelitian diharapkan mendukung proses stock-taking yang lebih cepat, konsisten, serta menjadi dasar pengembangan implementasi real-time pada proses operasional farmasi.

METODE PENELITIAN

2.1 Dataset

Dataset berisi 183 citra produk farmasi berformat JPEG dengan 11 kelas dan total 497 anotasi bounding box. Dataset dibagi menjadi 146 citra untuk pelatihan dan 37 citra untuk validasi (rasio 80:20). Distribusi label dan sebaran bounding box ditunjukkan pada Gambar 1.



Gambar 1 Distribusi label dan sebaran bounding box pada dataset.

Tabel 1 Distribusi dataset per kelas pada data latih dan validasi

I D	Kelas	Citra (Train)	BBox (Train)	Citra (Val)	BBox (Val)
0	cocoabutter_for_gcfuji_ionomerfilling	50	51	10	11
1	e-flex_blue-057	31	31	5	5
2	edenta_fgdiambondburs_studentkit	32	32	7	7
3	flexiband_matrixbands_dentamerica_no-1	30	32	7	7
4	formocresol	39	39	7	7
5	gc_goldlabel_hsposterior_extra	39	39	9	9
6	guttaperchapoints 120pcs	28	28	6	6
7	indodent_absorbent_paperpoints_size45-80	41	41	7	7
8	indodent_guttaperchapoints_size45-80	38	42	10	11
9	precaine_stroberry	44	44	8	8
10	shileld_dentin_desensitizer	31	31	9	9

2.2 Anotasi dan Format Label

Anotasi dilakukan menggunakan Label Studio dengan memberikan bounding box dan label kelas pada setiap objek. Hasil anotasi diekspor ke format YOLO sehingga setiap citra memiliki satu berkas label berekstensi .txt.

Setiap baris label mengikuti format: class_id x_center y_center width height, dengan koordinat ter-normalisasi terhadap lebar dan tinggi citra (rentang 0-1). Contoh visual anotasi pada batch validasi ditunjukkan pada Gambar 2.



Gambar 2 Contoh anotasi bounding box dan label kelas pada citra.

2.3 Pelatihan Model

Model deteksi objek dilatih menggunakan Ultralytics YOLO dengan bobot pralatih (pretrained). Arsitektur yang digunakan adalah YOLO11s dengan ukuran masukan 640 piksel dan batch size 16. Pelatihan dijalankan selama 60 epoch.

Pelatihan dilakukan menggunakan bobot pralatih (pretrained) YOLO11s pada framework Ultralytics. Konfigurasi mengikuti pengaturan standar Ultralytics, dengan optimizer dipilih otomatis oleh sistem (umumnya SGD/AdamW), learning rate awal sekitar 0,01, momentum sekitar 0,937, dan weight decay sekitar 0,0005. Augmentasi data diterapkan untuk meningkatkan

generalisasi, mencakup penyesuaian HSV, flipping horizontal, dan mosaik (serta transformasi geometri ringan seperti translate/scale) sesuai konfigurasi bawaan Ultralytics.

2.4 Evaluasi

Kinerja model dievaluasi menggunakan metrik standar deteksi objek: Precision, Recall, F1-score, $mAP@0.5$, dan $mAP@0.5:0.95$. Bobot terbaik (best.pt) dipilih berdasarkan kinerja pada data validasi.

2.5 Lingkungan Implementasi

Pelatihan dilakukan menggunakan Ultralytics YOLO dengan bobot pralatih. Model yang digunakan adalah YOLO11s. Proses pelatihan dijalankan selama 60 epoch dengan ukuran input 640 piksel. Bobot terbaik (best.pt) dipilih berdasarkan kinerja pada data validasi untuk memperoleh model dengan generalisasi yang baik.

2.6 Alur Sistem Otomasi Inventaris

Alur sistem yang diusulkan meliputi: (1) pengambilan citra produk pada rak atau gudang menggunakan kamera, (2) inferensi YOLO untuk mendeteksi kelas produk dan menghitung jumlah objek, (3) verifikasi hasil (opsional) oleh petugas, serta (4) pembaruan stok pada sistem inventaris. Dengan alur ini, audit stok dapat dipercepat dan dibuat lebih konsisten karena berbasis hasil deteksi otomatis.

HASIL DAN PEMBAHASAN

3.1 Distribusi Data

Distribusi jumlah citra dan bounding box pada data latih dan validasi per kelas ditunjukkan pada Tabel 1.

3.2 Hasil Evaluasi Model

Ringkasan metrik evaluasi pada epoch terbaik ditunjukkan pada Tabel 2. Performa terbaik diperoleh pada epoch ke-55 dengan $mAP@0.5$ sebesar 0.9796 dan $mAP@0.5:0.95$ sebesar 0.7565.


Tabel 2 Ringkasan metrik evaluasi pada epoch terbaik

Epoch terbaik	Precision	Recall	F1-score	$mAP@0.5$	$mAP@0.5:0.95$
55	0.9641	0.9218	0.9425	0.9796	0.7565

Nilai $mAP@0.5$ yang mendekati 1 menunjukkan kemampuan lokalisasi dan klasifikasi yang sangat baik pada ambang IoU 0.5. Namun, $mAP@0.5:0.95$ yang lebih rendah mengindikasikan akurasi lokalisasi bounding box masih dapat ditingkatkan ketika ambang IoU diperketat, terutama pada kondisi pantulan cahaya dan tumpang tindih antarproduk. Analisis kurva pelatihan, kesalahan umum, serta contoh prediksi ditampilkan pada Subbagian 3.3-3.5.

3.3 Analisis Kurva Pelatihan


Kurva pelatihan dan validasi pada Gambar 3 menunjukkan tren pembelajaran yang stabil hingga mendekati epoch terbaik. Pemilihan bobot terbaik pada epoch ke-55 menghasilkan precision 0.9641 dan recall 0.9218, yang mengindikasikan sebagian besar deteksi yang dihasilkan benar serta sebagian besar objek pada citra berhasil ditemukan. Kurva ini membantu memverifikasi kestabilan pelatihan dan kecenderungan konvergensi.



Gambar 3 Kurva pelatihan dan validasi model selama 60 epoch.

3.4 Analisis Kesalahan

Walaupun $mAP@0.5$ mencapai 0.9796, $mAP@0.5:0.95$ sebesar 0.7565 mengindikasikan bahwa pada ambang IoU yang lebih ketat, presisi lokalisasi bounding box masih dapat ditingkatkan. Kesalahan yang umum pada skenario inventaris meliputi: (1) pantulan cahaya pada kemasan sehingga batas objek kurang jelas, (2) tumpang tindih antarproduk yang menyebabkan sebagian objek terpotong, dan (3) kemiripan desain kemasan antarproduk yang berdekatan sehingga terjadi pertukaran label pada kasus tertentu. Confusion matrix pada Gambar 4 dapat digunakan untuk mengidentifikasi pasangan kelas yang paling sering tertukar.




Gambar 4 Confusion matrix ter-normalisasi untuk 11 kelas.

3.5 Implikasi untuk Inventaris

Secara operasional, model dapat digunakan untuk audit stok berbasis citra pada rak atau gudang. Output deteksi (kelas dan jumlah objek) dapat dikonversi menjadi rekap otomatis untuk membantu petugas melakukan verifikasi lebih cepat. Contoh hasil prediksi pada Gambar 5 menunjukkan potensi penggunaan sistem untuk inspeksi stok, sehingga proses pembaruan stok lebih konsisten dibanding pencatatan manual.

Ukuran dataset yang relatif terbatas meningkatkan risiko overfitting, terutama bila variasi pencahayaan, sudut pengambilan, dan latar belakang belum cukup beragam. Indikasi overfitting umumnya terlihat ketika performa training terus meningkat namun metrik pada validation stagnan/menurun. Untuk menekan risiko tersebut, penelitian ini memanfaatkan bobot pralatih, augmentasi data, serta pemilihan model terbaik berdasarkan evaluasi validasi. Meski demikian, validitas generalisasi masih perlu diperkuat melalui (1) penambahan data dari kondisi operasional nyata yang lebih beragam, (2) pengujian pada data eksternal (external test set), dan/atau (3) skema cross-validation. Langkah tersebut penting agar sistem lebih robust terhadap perubahan kemasan, refleksi, serta perbedaan jarak pengambilan gambar.



Gambar 5 Contoh hasil prediksi model pada data validasi.

3.6 Perbandingan dengan studi terkait

Hasil penelitian ini selaras dengan tren penerapan YOLO untuk pemantauan stok/OSA dan out-of-stock detection pada domain ritel, namun konteks farmasi memiliki tantangan tambahan berupa kemiripan visual kemasan dan kebutuhan akurasi tinggi untuk pelayanan

kesehatan. Studi ritel berbasis YOLOv7 dan penelitian OOS berbasis deep learning menunjukkan manfaat otomasi audit stok, sehingga pendekatan YOLO11s pada inventaris farmasi RSGM menjadi penguatan kontribusi pada domain yang lebih spesifik.

SIMPULAN

Penelitian ini berhasil membangun model deteksi objek untuk otomasi inventaris farmasi menggunakan dataset berformat YOLO. Model YOLO11s mencapai Precision 0,9641 dan Recall 0,9218 dengan mAP@0,5 sebesar 0,9796 serta mAP@0,5:0,95 sebesar 0,7565 pada data validasi. Secara keseluruhan, pendekatan yang diusulkan layak diterapkan untuk mengurangi pencatatan manual, mempercepat inspeksi stok, dan meningkatkan konsistensi pencatatan.

SARAN

1. Menambah jumlah data dan variasi kondisi pengambilan citra (pencahayaan, sudut, jarak, oklusi) serta menyeimbangkan jumlah sampel per kelas.
2. Melakukan eksperimen pembandingan dengan arsitektur lain (misalnya SSD dan Faster R-CNN) atau varian YOLO dengan kapasitas lebih besar, serta pencarian hyperparameter (learning rate, batch size, imgsz) untuk kombinasi terbaik.
3. Menerapkan augmentasi yang lebih realistis untuk skenario gudang/rak (misalnya motion blur ringan, perubahan eksposur, dan distorsi perspektif).
4. Mengintegrasikan hasil deteksi dengan sistem informasi inventaris (basis data) sehingga keluaran model dapat langsung memperbarui stok dan menghasilkan laporan otomatis.
5. Melakukan uji lapangan pada lingkungan nyata termasuk pengukuran latensi inferensi pada perangkat target.

DAFTAR PUSTAKA

1. D. Simchi-Levi, P. Kaminsky, and E. Simchi-Levi, *Designing and Managing the Supply Chain: Concepts, Strategies, and Case Studies*, 3rd ed. New York, NY, USA: McGraw-Hill, 2007.
2. D. Waters, *Inventory Control and Management*, 2nd ed. Chichester, UK: John Wiley & Sons, 2003.
3. A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems* (NeurIPS), 2012.
4. J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, real-time object detection," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition* (CVPR), 2016.
5. W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "SSD: Single Shot MultiBox Detector," in *Proc. European Conf. Computer Vision* (ECCV), 2016.
6. I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
7. S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," in *Advances in Neural Information Processing Systems* (NeurIPS), 2015.
8. K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition* (CVPR), 2016.
9. K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv:1409.1556*, 2014.
10. Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

11. K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biological Cybernetics*, vol. 36, pp. 193–202, 1980.
12. C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
13. Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
14. J. T. Springenberg, A. Dosovitskiy, T. Brox, and M. Riedmiller, "Striving for simplicity: The all convolutional net," in *ICLR Workshop*, 2015.
15. J. Bergstra and Y. Bengio, "Random search for hyper-parameter optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281–305, 2012.
16. S. B. Kotsiantis, "Supervised Machine Learning: A review of classification techniques," *Informatica*, vol. 31, pp. 249–268, 2007.
17. D. M. W. Powers, "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation," *Journal of Machine Learning Technologies*, vol. 2, no. 1, pp. 37–63, 2011.
18. C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors," in *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition (CVPR)*, 2023, pp. 7464–7475, doi: 10.1109/CVPR52729.2023.00721.
19. C.-Y. Wang, I.-H. Yeh, and H.-Y. M. Liao, "YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information," *ECCV Papers*, 2024; arXiv:2402.13616.
20. A. Wang, H. Chen, L. Liu, K. Chen, Z. Lin, J. Han, and G. Ding, "YOLOv10: Real-Time End-to-End Object Detection," arXiv:2405.14458, 2024.
21. Ultralytics, "Ultralytics YOLO11," *Ultralytics Documentation*, released Sep. 10, 2024.
22. F. Šikić, Z. Kalafatić, M. Subašić, and S. Lončarić, "Enhanced Out-of-Stock Detection in Retail Shelf Images Based on Deep Learning," *Sensors*, vol. 24, no. 2, Art. 693, 2024, doi: 10.3390/s24020693.
23. A. A. Septria, A. S. Handayani, and N. Nasron, "Real-Time Retail Shelf-Stock Detection with YOLOv7," *Jurnal Teknik Informatika*, vol. 18, no. 2, 2025, doi: 10.15408/jti.v18i2.46448.
24. D. H. Fudholi, A. Kurniawardhani, G. I. Andaru, A. A. Alhanafi, and N. Najmudin, "YOLO-based Small-scaled Model for On-Shelf Availability in Retail," *Jurnal RESTI*, vol. 8, no. 2, 2024, doi: 10.29207/resti.v8i2.5600.
25. G. P. Rizky A and R. Widyastuti, "Real Time Pill Counting on Low Power Device: A YOLOv5 Pipeline with Confidence Thresholding and NMS," *Jurnal Teknik Informatika C.I.T Medicom*, vol. 17, no. 5, 2025, doi: 10.35335/cit.Vol17.2025.1286.pp225-241.
26. Ultralytics, "Training settings / default hyperparameters and augmentation configuration," *Ultralytics YOLO Docs (Reference/Config)*, accessed Jan. 20, 2026.