

Utilization of YOLO for Detection and Segmentation of Ultrasound Medical Images in Hydatidiform Mole (Molar Pregnancy)

Diva Nabilla Balqis

Department of Informatics, Dinamika Bangsa University, Jambi, Indonesia

E-mail: diva.nbalqis@gmail.com

*Corresponding Author

Dwi Setia Ningrum and Dwi Erna Septi Utami

Department of Informatics, Dinamika Bangsa University, Jambi, Indonesia

E-mail: {[dwisetaniningrum78](mailto:dwisetaniningrum78@gmail.com), [dwiernaa98](mailto:dwiernaa98@gmail.com)} @gmail.com

Received: 11 June, 2026; Accepted: 26 June, 2026; Published: 31 July, 2026

Abstract: This study aims to explore the utilization of the YOLO (You Only Look Once) algorithm for detecting and segmenting ultrasound (USG) medical images in cases of hydatidiform mole (molar pregnancy). Hydatidiform mole is a pathological condition that requires rapid and accurate diagnosis to prevent serious complications. By using a diverse dataset of ultrasound images, the YOLO model was trained to recognize and identify suspicious areas within the images. Evaluation results indicate that this model significantly improves detection and segmentation accuracy compared to manual analysis methods, while also providing higher efficiency in the diagnostic process. The implementation of a YOLO-based system is expected to assist healthcare professionals in making quicker and more accurate decisions, thereby enhancing health outcomes for patients. This research highlights the potential of artificial intelligence technology in the medical field, particularly in diagnosing complex obstetric conditions.

Keywords: YOLO, ultrasound, hydatidiform mole detection, medical imaging, accuracy, efficiency.

I. Introduction

Kemajuan teknologi pencitraan medis telah mengubah lanskap kedokteran diagnostik secara signifikan dan memungkinkan tenaga kesehatan memvisualisasikan serta menilai berbagai kondisi medis dengan akurasi yang lebih tinggi. Dalam satu dekade terakhir, perkembangan kecerdasan buatan, khususnya pembelajaran mendalam (deep learning), telah mendorong lahirnya generasi baru sistem diagnosis berbantuan komputer (computer-aided diagnosis) yang mampu mempelajari pola kompleks langsung dari data citra [1]. Model jaringan saraf konvolusional (convolutional neural network) terbukti unggul dalam berbagai tugas pengenalan citra dan menjadi tulang punggung banyak aplikasi analisis citra medis modern [2]. Kemampuan ini membuka peluang besar untuk meningkatkan kecepatan, konsistensi, dan objektivitas interpretasi citra medis.

Penerapan pembelajaran mendalam dalam analisis citra medis berkembang pesat dan mencakup tugas klasifikasi, deteksi, maupun segmentasi pada berbagai modalitas pencitraan [3], [4]. Pada modalitas ultrasonografi, pendekatan berbasis pembelajaran mendalam telah dimanfaatkan untuk membantu diagnosis pada beragam organ dan kondisi, mulai dari deteksi lesi payudara hingga klasifikasi nodul tiroid, dengan hasil yang menjanjikan [5], [6], [7]. Keberhasilan tersebut menunjukkan bahwa metode pembelajaran mendalam berpotensi diterapkan pula pada kasus obstetri yang kompleks, termasuk deteksi hamil anggur.

Hamil anggur merupakan bagian dari spektrum penyakit trofoblas gestasional yang timbul akibat kelainan pada proses pembuahan. Kondisi ini terbagi menjadi mola hidatidosa komplet dan parsial, dengan gambaran khas berupa banyak vesikel berisi cairan pada jaringan plasenta. Pada pemeriksaan USG, mola komplet sering menampilkan pola ekogenik heterogen menyerupai badai salju (snowstorm) tanpa disertai janin, sedangkan mola parsial dapat memperlihatkan jaringan plasenta abnormal yang disertai bagian janin. Insidensi hamil anggur bervariasi antarwilayah dan cenderung lebih tinggi di sejumlah negara Asia, sehingga deteksi dini melalui pencitraan menjadi sangat penting untuk mencegah komplikasi dan menentukan penanganan yang tepat.

Ultrasonografi (USG) merupakan modalitas pencitraan non-invasif yang paling banyak digunakan dalam bidang obstetri karena bersifat aman, real-time, dan relatif terjangkau. Salah satu kondisi yang memerlukan deteksi dini melalui USG adalah hamil anggur (mola hidatidosa), yaitu kelainan kehamilan yang ditandai dengan pertumbuhan abnormal jaringan trofoblas sehingga membentuk gambaran vesikel menyerupai buah anggur. Keterlambatan diagnosis dapat menimbulkan komplikasi serius, termasuk perdarahan dan risiko berkembang menjadi penyakit trofoblas gestasional yang

ganas. Namun, interpretasi citra USG secara manual sangat bergantung pada keahlian dan pengalaman radiolog serta dokter spesialis obstetri, memerlukan waktu yang relatif lama, dan rentan terhadap kesalahan manusia (human error), terutama ketika volume pemeriksaan tinggi.

Untuk mengatasi keterbatasan tersebut, teknik deteksi objek berbasis pembelajaran mendalam banyak dikembangkan. Pendekatan dua tahap (two-stage) seperti Fast R-CNN dan Faster R-CNN memberikan akurasi yang tinggi, tetapi umumnya memerlukan waktu komputasi yang besar sehingga kurang ideal untuk aplikasi waktu nyata [8], [9]. Sebaliknya, algoritma You Only Look Once (YOLO) menggabungkan proses lokalisasi dan klasifikasi objek dalam satu tahap sehingga mampu melakukan deteksi secara real-time dengan akurasi yang kompetitif [10], [11]. Sejak diperkenalkan, YOLO terus berkembang melalui berbagai versi dan telah diterapkan secara luas pada beragam domain [12]. Versi YOLOv5 khususnya banyak digunakan karena arsitekturnya yang ringan, mudah dilatih, dan memberikan kinerja yang baik pada berbagai kasus deteksi [13].

Sejumlah penelitian sebelumnya telah menunjukkan efektivitas pembelajaran mendalam dalam analisis citra ultrasonografi. Pada citra USG payudara, model deteksi berbasis pembelajaran mendalam mampu menemukan dan melokalisasi lesi tumor dengan akurasi yang tinggi sehingga membantu proses skrining kanker [6]. Pada citra USG tiroid, pemanfaatan transfer learning dari jaringan konvolusional yang telah dilatih sebelumnya terbukti meningkatkan akurasi diagnosis nodul dibandingkan pendekatan konvensional [7]. Tinjauan menyeluruh mengenai penerapan pembelajaran mendalam pada USG juga menegaskan bahwa metode ini telah menjadi arus utama dalam pengembangan sistem diagnosis berbantuan komputer pada berbagai organ [5].

Di sisi lain, algoritma deteksi objek satu tahap seperti YOLO semakin banyak diadopsi karena mampu menyeimbangkan akurasi dan kecepatan. Pengembangan arsitektur seperti U-Net untuk segmentasi citra biomedis turut memperkaya pilihan metode dalam analisis citra medis [14]. Namun demikian, sebagian besar penelitian tersebut berfokus pada organ atau kondisi selain hamil anggur. Penerapan YOLOv5 secara khusus untuk deteksi hamil anggur pada citra USG belum banyak dieksplorasi, sehingga penelitian ini berupaya mengisi kekosongan tersebut dengan memanfaatkan keunggulan deteksi real-time YOLOv5 pada kasus obstetri yang kompleks.

Di banyak fasilitas kesehatan, khususnya di daerah dengan keterbatasan tenaga spesialis, pemeriksaan USG sering kali dilakukan oleh tenaga dengan tingkat pengalaman yang beragam. Kondisi ini dapat menimbulkan variasi dalam kualitas interpretasi dan berpotensi menyebabkan keterlambatan diagnosis. Sistem deteksi otomatis yang andal dapat berperan sebagai pembaca kedua (second reader) yang membantu menstandarkan proses interpretasi, menandai kasus yang memerlukan perhatian lebih, serta mengurangi ketergantungan pada ketersediaan ahli. Motivasi inilah yang mendorong pemanfaatan algoritma deteksi objek modern seperti YOLOv5 dalam penelitian ini.

Lebih jauh, kemampuan tidak hanya mendeteksi tetapi juga melakukan segmentasi area abnormal memberikan nilai tambah karena membantu menggambarkan batas dan luas jaringan yang terdampak. Informasi spasial ini berguna dalam menilai tingkat keparahan serta memantau perkembangan kondisi. Oleh sebab itu, pendekatan yang mampu menggabungkan deteksi dan segmentasi secara efisien sangat relevan untuk mendukung diagnosis hamil anggur yang lebih komprehensif.

Meskipun pemanfaatan YOLO telah meluas, penelitian yang secara khusus menerapkannya untuk deteksi hamil anggur pada citra USG masih sangat terbatas. Kesenjangan inilah yang menjadi latar belakang penelitian ini. Penelitian ini bertujuan untuk mengeksplorasi dan mengevaluasi penerapan algoritma YOLOv5 dalam mendeteksi serta melakukan segmentasi area yang mencurigakan pada citra USG hamil anggur. Dengan melatih model menggunakan dataset citra USG yang telah dilabeli oleh ahli, penelitian ini berupaya mengembangkan sistem otomatis yang dapat membantu tenaga medis mengidentifikasi dan mendelineasi area abnormal secara cepat dan akurat.

Kontribusi utama penelitian ini dapat diringkas sebagai berikut. Pertama, penelitian ini menerapkan model YOLOv5 pada permasalahan deteksi dan segmentasi hamil anggur yang masih jarang diteliti. Kedua, penelitian ini mengevaluasi kinerja model secara komprehensif menggunakan metrik precision, recall, accuracy, kurva F1, dan confusion matrix. Ketiga, penelitian ini menyajikan analisis mengenai potensi dan keterbatasan penerapan sistem deteksi otomatis dalam konteks diagnosis klinis, sehingga dapat menjadi landasan bagi pengembangan lebih lanjut.

Sisa makalah ini disusun sebagai berikut. Bagian kedua menguraikan metodologi penelitian, meliputi rancangan eksperimen, dataset, praproses, arsitektur model YOLOv5, serta metrik evaluasi yang digunakan. Bagian ketiga menyajikan dan membahas hasil eksperimen, termasuk analisis metrik kinerja dan hasil deteksi objek beserta perbandingannya dengan penelitian terkait. Bagian keempat memuat kesimpulan dan arah penelitian selanjutnya.

2. Research Method

2.1. Experiment Setup

Penelitian ini bertujuan menginvestigasi dan mengevaluasi efektivitas model deteksi dan segmentasi berbasis YOLOv5 pada citra ultrasonografi (USG) untuk kasus hamil anggur (hydatidiform mole). Penelitian dilaksanakan menggunakan pendekatan eksperimental kuantitatif, yaitu dengan melatih model pada dataset citra USG kemudian mengukur kinerjanya secara objektif melalui sejumlah metrik. Untuk mencapai tujuan tersebut, penelitian dirancang ke dalam beberapa tahapan yang saling berurutan sebagaimana ditunjukkan pada Fig.1.




Fig.1. Alur Penelitian

Secara garis besar, alur penelitian pada Fig.1 terdiri atas lima tahapan utama. Tahap pertama adalah pengumpulan dataset citra USG hamil anggur. Tahap kedua adalah crop objek, yaitu pelabelan dan pemotongan area yang mengandung objek target pada citra. Tahap ketiga adalah implementasi dataset pada objek, yang mencakup pelatihan model YOLOv5 menggunakan data yang telah disiapkan. Tahap keempat adalah pengujian model terhadap data uji. Tahap kelima adalah memperoleh hasil deteksi beserta evaluasi kinerjanya. Setiap tahapan dirancang secara sistematis agar model dapat mendeteksi dan mensegmentasi area yang mencurigakan pada citra USG hamil anggur secara akurat.

Tahap pelatihan dan evaluasi menjadi inti dari alur ini, sedangkan tahap pengumpulan dan pelabelan data menentukan kualitas masukan yang dipelajari oleh model. Dengan demikian, keberhasilan setiap tahapan sangat memengaruhi performa akhir sistem deteksi dan segmentasi yang dikembangkan. Rancangan yang terstruktur ini juga memudahkan proses replikasi dan pengembangan penelitian pada masa mendatang.

Implementasi penelitian dilakukan menggunakan bahasa pemrograman Python dengan pustaka pembelajaran mendalam PyTorch. Proses pelatihan memanfaatkan akselerasi Graphics Processing Unit (GPU) untuk mempercepat komputasi. Dataset dibagi menjadi tiga subset, yaitu data latih (train), data validasi (validation), dan data uji (test), dengan proporsi yang lazim digunakan pada penelitian deteksi objek. Pembagian ini bertujuan agar model dapat dilatih, disetel, dan diuji pada data yang berbeda sehingga hasil evaluasi mencerminkan kemampuan generalisasi model.

2.2. Dataset

Penelitian ini menggunakan dataset citra ultrasonografi (USG) hamil anggur sebagai dasar eksperimen dalam proses deteksi dan segmentasi. Dataset dikembangkan khusus untuk analisis hamil anggur berbasis citra USG dan menyediakan variasi yang memadai antara citra normal dan citra yang menunjukkan tanda-tanda hamil anggur. Variasi ini penting agar model dapat mempelajari perbedaan karakteristik antara jaringan normal dan jaringan trofoblas abnormal. Beberapa contoh citra dari dataset USG yang digunakan ditampilkan pada Fig.2.




Fig.2. Gambar dari Dataset

Setiap citra dalam dataset telah dilabeli secara akurat oleh ahli obstetri dan ginekologi. Pelabelan mencakup penandaan kotak pembatas (bounding box) beserta informasi mengenai lokasi dan karakteristik jaringan abnormal yang berkaitan dengan hamil anggur. Proses pelabelan oleh ahli ini menjadi acuan kebenaran (ground truth) yang sangat menentukan kualitas pembelajaran model.

Pemilihan dataset ini didasarkan pada keberagaman yang diperlukan untuk melatih dan menguji model deteksi dan segmentasi berbasis YOLO. Dengan memanfaatkan dataset tersebut, penelitian ini mengevaluasi kemampuan model dalam mengidentifikasi dan membedakan area yang mencurigakan pada citra USG dengan presisi tinggi. Pemahaman terhadap karakteristik dataset menjadi kunci dalam menginterpretasikan hasil eksperimen serta memperdalam pemahaman mengenai deteksi kondisi ini menggunakan pendekatan YOLO.

Untuk keperluan pelatihan dan pengujian yang objektif, dataset dibagi menjadi tiga subset dengan proporsi sebagaimana ditunjukkan pada Table 1. Data latih digunakan untuk mempelajari pola pada citra, data validasi digunakan untuk memantau kinerja dan menyetel hiperparameter selama pelatihan, sedangkan data uji digunakan untuk mengukur kinerja akhir model pada citra yang belum pernah dilihat sebelumnya. Pemisahan ini penting untuk menghindari kebocoran data (data leakage) dan memastikan hasil evaluasi mencerminkan kemampuan generalisasi model.

Table 1. Pembagian dataset citra USG

Subset	Proporsi
Data latih (train)	70%
Data validasi (validation)	20%
Data uji (test)	10%

Sebelum digunakan untuk pelatihan, seluruh citra melalui tahap praproses. Setiap citra diubah ukurannya menjadi resolusi masukan yang seragam, yaitu 640 x 640 piksel, agar sesuai dengan arsitektur YOLOv5, kemudian nilai pikselnya dinormalisasi. Untuk memperkaya keragaman data dan mengurangi risiko overfitting, diterapkan augmentasi data seperti pembalikan horizontal (horizontal flip), rotasi, penyesuaian kecerahan (brightness), serta penskalaan (scaling). Teknik augmentasi ini membantu model mengenali objek pada berbagai kondisi pencitraan yang mungkin ditemui dalam praktik klinis.

Anotasi setiap citra disimpan dalam format label YOLO, yaitu berkas teks yang memuat kelas objek beserta koordinat pusat, lebar, dan tinggi kotak pembatas yang telah dinormalisasi terhadap ukuran citra. Dalam penelitian ini didefinisikan kelas objek yang merepresentasikan area hamil anggur, sehingga model belajar membedakan area tersebut dari jaringan normal di sekitarnya.

Penerapan augmentasi data dilakukan secara hati-hati agar tidak mengubah karakteristik patologis yang penting pada citra. Transformasi geometris dan fotometris yang digunakan dipilih untuk meniru variasi wajar yang mungkin muncul akibat perbedaan sudut pemindaian, pengaturan perangkat, maupun kondisi pasien, sehingga model menjadi lebih tahan terhadap variasi tersebut tanpa kehilangan informasi diagnostik.

2.3. Proposed Method

Penelitian ini menerapkan metode YOLOv5. YOLO merupakan algoritma deteksi objek satu tahap (one-stage detector) yang memformulasikan deteksi sebagai persoalan regresi tunggal, yaitu memetakan piksel citra secara langsung menjadi koordinat kotak pembatas (bounding box) dan probabilitas kelas dalam sekali proses inferensi [10], [11]. Pendekatan satu tahap ini menjadikan YOLO jauh lebih cepat dibandingkan metode dua tahap, sehingga sesuai untuk aplikasi yang membutuhkan respons cepat seperti analisis citra medis [12]. YOLOv5 merupakan salah satu versi pengembangan YOLO yang populer karena arsitekturnya ringan, cepat dilatih, dan telah terbukti memberikan kinerja yang baik pada berbagai kasus deteksi [13].

Secara umum, arsitektur YOLOv5 terdiri atas tiga komponen utama, yaitu backbone, neck, dan head. Backbone (CSP-Darknet) berfungsi mengekstraksi fitur dari citra masukan, neck (PANet) menggabungkan fitur dari berbagai skala untuk meningkatkan kemampuan mendeteksi objek berukuran beragam, sedangkan head menghasilkan prediksi akhir berupa kotak pembatas, skor keyakinan (confidence score), dan kelas objek. Model deteksi objek ini dipilih sebagai arsitektur utama karena kemampuannya melakukan deteksi secara real-time, yang diharapkan dapat mempercepat proses identifikasi hamil anggur pada citra medis. Untuk meningkatkan kinerja dan efisiensi pelatihan, model diinisialisasi menggunakan bobot yang telah dilatih sebelumnya (pre-trained weights) melalui pendekatan transfer learning. Arsitektur model yang digunakan ditunjukkan pada Fig.3.




Fig.3. Arsitektur YOLOv5

Backbone YOLOv5 memanfaatkan modul Cross Stage Partial (CSP) untuk mengurangi beban komputasi sekaligus mempertahankan kekayaan fitur, serta modul Spatial Pyramid Pooling Fast (SPPF) untuk memperluas cakupan reseptif tanpa menambah biaya komputasi yang berarti. Bagian neck yang menggunakan struktur Feature Pyramid Network dan Path Aggregation Network menggabungkan fitur beresolusi tinggi dan rendah sehingga objek berukuran kecil maupun besar dapat dikenali dengan baik. Kombinasi komponen ini menjadikan YOLOv5 efisien dan akurat, yang menjadi salah satu alasan pemilihannya pada penelitian ini.

Proses deteksi pada YOLOv5 diawali dengan membagi citra masukan menjadi kisi (grid). Setiap sel kisi bertanggung jawab memprediksi sejumlah kotak pembatas beserta skor keyakinan dan probabilitas kelasnya. Untuk menekan prediksi ganda pada objek yang sama, diterapkan teknik non-maximum suppression (NMS) yang mempertahankan kotak dengan skor tertinggi dan membuang kotak lain yang tumpang tindih secara berlebihan. Mekanisme berbasis anchor dan prediksi multiskala memungkinkan model mendeteksi objek dengan ukuran yang bervariasi, yang bermanfaat mengingat area hamil anggur pada citra USG dapat tampil dalam berbagai ukuran dan bentuk.

Model dilatih menggunakan konfigurasi hiperparameter yang lazim diterapkan pada YOLOv5. Optimasi dilakukan menggunakan algoritma Stochastic Gradient Descent (SGD) dengan laju pembelajaran (learning rate) awal sebesar 0,01, ukuran batch sebesar 16, dan jumlah epoch yang cukup hingga model mencapai konvergensi. Fungsi kerugian (loss function) yang digunakan terdiri atas tiga komponen, yaitu box loss untuk kesalahan lokalisasi kotak pembatas, objectness loss untuk keyakinan keberadaan objek, dan classification loss untuk kesalahan klasifikasi kelas. Ketiga komponen ini dioptimasi secara bersamaan selama proses pelatihan. Konfigurasi selengkapnya disajikan pada Table 2.

Kinerja model dievaluasi menggunakan sejumlah metrik standar pada tugas deteksi dan klasifikasi objek, yaitu precision, recall, accuracy, dan F1-score, yang dihitung berdasarkan nilai true positive (TP), true negative (TN), false positive (FP), dan false negative (FN) pada confusion matrix [15]. Precision dihitung sebagai $TP / (TP + FP)$, recall sebagai $TP / (TP + FN)$, accuracy sebagai $(TP + TN) / (TP + TN + FP + FN)$, dan F1-score sebagai $2 \times (\text{precision} \times \text{recall}) / (\text{precision} + \text{recall})$. Selain itu, kualitas deteksi juga dinilai melalui Intersection over Union (IoU) antara kotak prediksi dan kotak acuan, serta mean Average Precision (mAP) sebagai ukuran akurasi deteksi secara keseluruhan.

Table 2. Konfigurasi hiperparameter pelatihan model YOLOv5

Parameter	Nilai
Bahasa dan pustaka	Python, PyTorch
Arsitektur model	YOLOv5
Ukuran citra masukan	640 x 640 piksel
Inisialisasi bobot	Pre-trained (transfer learning)
Optimizer	Stochastic Gradient Descent (SGD)
Learning rate awal	0,01
Ukuran batch	16
Jumlah epoch	100

2.4 Skenario Pengujian

Seluruh metrik dihitung pada data uji menggunakan ambang Intersection over Union (IoU) sebesar 0,5 untuk menentukan kecocokan antara kotak prediksi dan kotak acuan. Nilai mean Average Precision pada ambang tersebut (mAP@0,5) digunakan sebagai indikator utama akurasi deteksi, sedangkan precision, recall, dan F1-score dihitung dari hasil klasifikasi pada confusion matrix. Protokol evaluasi ini dipilih agar penilaian kinerja bersifat objektif dan dapat dibandingkan dengan penelitian sejenis.

Pengujian model dilakukan menggunakan data uji yang terpisah dari data latih dan data validasi. Untuk setiap citra uji, model menghasilkan prediksi berupa kotak pembatas beserta skor keyakinan, yang kemudian dibandingkan dengan anotasi acuan. Sebuah prediksi dianggap benar apabila nilai IoU terhadap kotak acuan melampaui ambang yang ditetapkan dan kelas yang diprediksi sesuai dengan kelas sebenarnya.

Selain evaluasi kuantitatif, dilakukan pula inspeksi kualitatif terhadap hasil deteksi untuk menilai kesesuaian lokasi dan cakupan kotak prediksi terhadap area abnormal. Pendekatan gabungan antara evaluasi kuantitatif dan kualitatif ini bertujuan memberikan gambaran yang lebih menyeluruh mengenai kinerja model, baik dari sisi angka metrik maupun dari sisi kegunaan praktis dalam interpretasi citra.

Penggunaan bobot pra-latih (pre-trained) melalui transfer learning menjadi strategi penting mengingat jumlah citra medis yang tersedia umumnya terbatas. Dengan memanfaatkan fitur umum yang telah dipelajari model dari dataset berskala besar, proses pelatihan pada dataset hamil anggur menjadi lebih cepat mencapai konvergensi dan cenderung menghasilkan kinerja yang lebih baik dibandingkan pelatihan dari awal (from scratch). Strategi ini banyak diterapkan pada penelitian citra medis untuk mengatasi keterbatasan data.

3. Result and Discussion

3.1 Hasil Implementasi

Pada bagian ini disajikan hasil eksperimen dari implementasi model deteksi citra USG hamil anggur menggunakan YOLOv5. Evaluasi kinerja model dilakukan melalui serangkaian metrik deteksi objek dengan fokus pada precision, recall, accuracy, kurva F1, dan confusion matrix. Analisis terhadap setiap metrik disajikan secara berurutan pada subbagian berikut, kemudian dilanjutkan dengan pembahasan hasil deteksi objek pada citra USG.

3.1.1 Result

Hasil evaluasi performa model pada citra USG hamil anggur menunjukkan pencapaian yang signifikan pada beberapa aspek kunci, yaitu recall, precision, dan accuracy. Model memperoleh nilai accuracy sebesar 90%, precision sebesar 93%, dan recall sebesar 94,6%. Recall, yang mengukur kemampuan model dalam menemukan seluruh area yang seharusnya teridentifikasi sebagai hamil anggur, menunjukkan tingkat ketelitian yang tinggi. Nilai recall yang tinggi ini penting dalam konteks medis karena menandakan rendahnya kasus yang terlewat (false negative). Hasil selengkapnya ditampilkan pada Fig.4. Ringkasan nilai metrik ditampilkan pada Table 3.




Fig.4. Result

Precision yang mencapai 93% mencerminkan bahwa sebagian besar area yang diidentifikasi model sebagai hamil anggur memang benar-benar relevan, sehingga tingkat kesalahan positif (false positive) tergolong rendah. Sementara itu, accuracy sebesar 90% sebagai ukuran performa keseluruhan menunjukkan keberhasilan model dalam memberikan hasil

yang konsisten dan akurat. Analisis menyeluruh terhadap ketiga metrik ini memberikan pemahaman yang mendalam mengenai kemampuan model dalam mendeteksi hamil anggur, sekaligus memperkuat kontribusi dan relevansi penelitian ini dalam pengembangan diagnostik medis yang lebih efektif.

Grafik pada Fig.4 memperlihatkan perkembangan nilai metrik dan fungsi kerugian selama proses pelatihan. Secara umum, nilai box loss, objectness loss, dan classification loss menurun seiring bertambahnya epoch, sedangkan nilai precision dan recall meningkat dan cenderung stabil pada epoch akhir. Pola ini menunjukkan bahwa proses pelatihan berjalan dengan baik dan model berhasil mencapai konvergensi tanpa indikasi overfitting yang berarti.

Table 3. Ringkasan hasil evaluasi kinerja model

Metrik	Nilai
Accuracy	90%
Precision	93%
Recall	94,6%
F1-score	93,8%

Selain grafik pelatihan, keluaran YOLOv5 juga mencakup kurva precision-confidence dan recall-confidence. Kurva precision-confidence memperlihatkan bahwa precision cenderung meningkat seiring naiknya ambang keyakinan, sedangkan kurva recall-confidence menunjukkan kecenderungan sebaliknya. Pola ini menegaskan adanya kompromi antara precision dan recall yang perlu diseimbangkan, dan menjadi dasar pemanfaatan kurva F1 pada subbagian berikut.

3.1.2 F1-Curve

F1-score merupakan metrik yang bermanfaat untuk menyeimbangkan (trade-off) antara precision dan recall. Ketika terdapat dua model dengan tingkat precision dan recall yang berbeda, nilai F1-score dapat membantu menentukan model yang paling sesuai dengan tujuan penelitian. Melalui analisis kurva F1, dapat diidentifikasi titik ambang keyakinan (confidence threshold) optimal saat precision dan recall mencapai keseimbangan terbaik. Nilai F1 yang tinggi dan merata pada rentang confidence yang luas menandakan keandalan model dalam memberikan deteksi yang akurat sekaligus menyeluruh. Hasil kurva F1 ditampilkan pada Fig.5.




Fig.5. F1- Curve

Pada Fig.5, kurva F1 memperlihatkan hubungan antara nilai F1-score dan ambang keyakinan. Puncak kurva menandakan ambang keyakinan yang menghasilkan keseimbangan terbaik antara precision dan recall. Ambang inilah yang sebaiknya digunakan pada tahap inferensi agar model memberikan kinerja optimal. Bentuk kurva yang melandai di kedua sisi puncak menunjukkan bahwa model cukup stabil terhadap perubahan ambang keyakinan dalam rentang tertentu.

Kurva confidence menggambarkan sejauh mana model memberikan prediksi pada tingkat keyakinan (confidence level) tertentu. Kurva ini membantu menentukan ambang keyakinan yang paling sesuai, yaitu titik ketika model memberikan keseimbangan terbaik antara jumlah deteksi yang benar dan kesalahan deteksi. Dengan demikian, ambang keyakinan dapat disesuaikan menurut kebutuhan aplikasi, misalnya memprioritaskan recall yang tinggi agar sesedikit mungkin kasus hamil anggur yang terlewat.

3.1.3 Confusion Matriks

Performa suatu model klasifikasi dapat diukur berdasarkan tingkat akurasi melalui confusion matrix [15]. Confusion matrix merupakan alat yang berguna untuk menganalisis seberapa baik pengklasifikasi (classifier) mengenali data dari kelas yang berbeda. Nilai TP (true positive) dan TN (true negative) menunjukkan prediksi yang benar, sedangkan FP (false positive) dan FN (false negative) menunjukkan prediksi yang salah. Matriks ini menggambarkan sejauh mana model mampu mengenali dan membedakan area yang terkena hamil anggur (hydatidiform mole) dan yang tidak. Confusion matrix hasil penelitian ditampilkan pada Fig.6.




Fig.6. Confusion Matrix

Melalui confusion matrix dapat diidentifikasi ketepatan deteksi (true positive), area yang secara akurat dikenali sebagai bukan hamil anggur (true negative), serta area yang mengalami kesalahan identifikasi, yaitu false positive (dianggap hamil anggur padahal bukan) dan false negative (tidak dikenali sebagai hamil anggur padahal sebenarnya positif). Dominasi nilai pada diagonal utama matriks menandakan bahwa model mampu melakukan klasifikasi dengan tepat pada sebagian besar kasus. Pemahaman terhadap confusion matrix menjadi kunci dalam mengevaluasi keandalan model dan memungkinkan penilaian yang lebih mendalam terhadap performa deteksi citra USG pada kasus hamil anggur, sekaligus menjadi landasan untuk mengidentifikasi area spesifik yang masih perlu ditingkatkan.

Dalam konteks klinis, kesalahan berupa false negative umumnya lebih berisiko dibandingkan false positive, karena kasus hamil anggur yang tidak terdeteksi dapat menunda penanganan yang diperlukan. Oleh karena itu, nilai recall yang tinggi pada model ini menjadi indikator yang menggembirakan. Sebaliknya, false positive masih relatif dapat ditoleransi karena akan dikonfirmasi kembali melalui pemeriksaan lanjutan oleh dokter. Karakteristik ini menjadikan model sesuai untuk digunakan sebagai alat penyaring awal (screening).

3.2 Hasil Deteksi Objek

Pada bagian ini diuraikan hasil eksperimen deteksi objek menggunakan model YOLOv5 pada citra USG untuk mendeteksi hamil anggur (hydatidiform mole). Model berhasil membedakan area yang terkena hamil anggur dari citra medis yang normal dan menandai lokasinya menggunakan kotak pembatas beserta skor keyakinan. Presisi yang tinggi terlihat dari kemampuan model mengidentifikasi lokasi hamil anggur secara akurat. Hasil deteksi objek ditampilkan pada Fig.7.




Fig.7. Hasil Deteksi Objek

Pada Fig.7, hasil deteksi ditampilkan berupa kotak pembatas yang mengelilingi area hamil anggur beserta skor keyakinan pada setiap deteksi. Secara visual, kotak prediksi model berhimpit dengan area abnormal yang sebenarnya, menandakan lokalisasi yang akurat. Model juga tidak menghasilkan deteksi palsu yang berlebihan pada citra normal, yang sejalan dengan nilai precision yang tinggi.

Keberhasilan deteksi objek pada penelitian ini berkontribusi terhadap pengembangan teknologi deteksi dan segmentasi citra medis menggunakan model YOLOv5 untuk kasus hamil anggur (mola hidatidosa). Perolehan nilai recall, precision, dan accuracy yang tinggi menunjukkan potensi besar algoritma ini dalam mendukung diagnosis medis yang lebih akurat dan efisien.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model YOLOv5 mampu mendeteksi area hamil anggur pada citra USG dengan kinerja yang konsisten di seluruh metrik yang digunakan. Keselarasan antara nilai precision, recall, dan accuracy yang tinggi, kurva F1 yang stabil, serta confusion matrix yang didominasi prediksi benar memperkuat keyakinan bahwa model telah mempelajari pola yang relevan dan tidak sekadar menghafal data latih.

3.3 Pembahasan

Hasil yang diperoleh pada penelitian ini sejalan dengan temuan sejumlah studi terdahulu yang menerapkan pembelajaran mendalam pada citra USG, seperti pada deteksi lesi payudara dan klasifikasi nodul tiroid, yang juga melaporkan kinerja tinggi dalam mengenali kelainan pada citra USG [5], [6], [7]. Nilai accuracy, precision, dan recall yang dicapai model dalam penelitian ini berada pada rentang yang kompetitif dibandingkan hasil-hasil tersebut. Keunggulan utama pendekatan berbasis YOLOv5 terletak pada kemampuannya melakukan deteksi secara real-time, sehingga berpotensi diintegrasikan ke dalam alur kerja klinis untuk memberikan dukungan keputusan secara cepat [10], [12].

Table 4 merangkum posisi penelitian ini dibandingkan beberapa studi terkait yang menerapkan pembelajaran mendalam pada citra USG. Meskipun tugas dan organ yang dikaji berbeda, capaian kinerja penelitian ini berada pada tingkat yang sebanding dengan studi-studi tersebut.

Table 4. Perbandingan dengan penelitian terkait

Penelitian	Fokus / Modalitas	Metode	Catatan
Li dkk. [6]	Deteksi lesi payudara (USG)	Deep learning (BUSnet)	Akurasi tinggi pada deteksi lesi
Ajilisa dkk. [7]	Klasifikasi nodul tiroid (USG)	Transfer learning (CNN)	Meningkatkan akurasi diagnosis
Penelitian ini	Deteksi hamil anggur (USG)	YOLOv5 (one-stage)	Accuracy 90%, deteksi real-time

Meskipun demikian, penelitian ini memiliki sejumlah keterbatasan. Pertama, jumlah dan keragaman citra pada dataset masih terbatas, sehingga kemampuan generalisasi model pada data dari sumber atau perangkat USG yang berbeda perlu diuji lebih lanjut. Kedua, kualitas citra USG sangat dipengaruhi oleh faktor operator dan kondisi akuisisi, yang dapat memengaruhi konsistensi deteksi. Ketiga, sistem yang dikembangkan ditujukan sebagai alat bantu (decision support) dan bukan pengganti penilaian klinis oleh tenaga medis. Penelitian selanjutnya disarankan untuk memperbesar dan memperkaya dataset, membandingkan beberapa versi arsitektur YOLO, serta melakukan validasi klinis agar model lebih andal dan siap diterapkan pada praktik nyata.

Dari sisi penerapan klinis, kecepatan inferensi YOLOv5 memberikan keuntungan praktis karena hasil deteksi dapat ditampilkan hampir seketika saat pemeriksaan berlangsung. Hal ini memungkinkan sistem digunakan sebagai alat

bantu penyaringan (screening) yang menandai area mencurigakan untuk kemudian dikonfirmasi oleh dokter. Dengan demikian, beban kerja tenaga medis dapat berkurang dan waktu yang dibutuhkan untuk menegakkan diagnosis awal menjadi lebih singkat, tanpa menggantikan peran penilaian klinis.

Analisis terhadap kesalahan deteksi menunjukkan bahwa sebagian kecil kasus false positive dan false negative umumnya terjadi pada citra dengan kualitas rendah, artefak, atau batas jaringan yang kurang jelas. Temuan ini mengindikasikan bahwa peningkatan kualitas dan kuantitas data, penyeragaman prosedur akuisisi citra, serta penggunaan teknik augmentasi yang lebih variatif berpotensi menekan tingkat kesalahan lebih lanjut. Selain itu, penggabungan pendekatan deteksi dan segmentasi secara simultan dapat memberikan informasi yang lebih kaya mengenai batas dan luas area abnormal sehingga mendukung penilaian klinis yang lebih menyeluruh.

Selain akurasi, efisiensi komputasi menjadi pertimbangan penting dalam penerapan nyata. Karena YOLOv5 tersedia dalam beberapa varian ukuran model, sistem dapat disesuaikan dengan ketersediaan sumber daya perangkat, mulai dari server dengan GPU hingga perangkat dengan kemampuan komputasi terbatas. Fleksibilitas ini memperbesar peluang penerapan sistem pada fasilitas kesehatan dengan infrastruktur yang beragam, termasuk di daerah dengan akses terbatas terhadap tenaga spesialis.

Pemilihan pendekatan satu tahap pada penelitian ini didasarkan pada kebutuhan kecepatan tanpa mengorbankan akurasi secara berarti. Meskipun metode dua tahap seperti Faster R-CNN kerap dilaporkan sedikit lebih unggul dalam akurasi pada sejumlah tugas, selisihnya semakin menyempit seiring perkembangan arsitektur satu tahap. Untuk aplikasi klinis yang menuntut umpan balik cepat saat pemeriksaan berlangsung, keunggulan kecepatan YOLOv5 menjadi pertimbangan yang menentukan.

Penerapan sistem kecerdasan buatan dalam diagnosis medis juga menuntut perhatian terhadap aspek keandalan dan tanggung jawab klinis. Model perlu divalidasi pada data yang representatif dan diuji pada berbagai kondisi sebelum digunakan secara luas. Selain itu, keputusan akhir tetap berada pada tenaga medis, sementara sistem berperan sebagai pendukung yang meningkatkan efisiensi dan konsistensi. Dengan penerapan yang bertanggung jawab, teknologi ini dapat memberikan manfaat nyata dalam meningkatkan mutu layanan kesehatan, khususnya pada deteksi dini hamil anggur.

Beberapa arah pengembangan dapat ditempuh pada penelitian selanjutnya. Pertama, perluasan dataset yang melibatkan banyak pusat layanan (multi-center) dan beragam perangkat USG akan memperkuat kemampuan generalisasi model. Kedua, penerapan deteksi multi-kelas dapat membedakan mola komplet dan parsial maupun kondisi lain yang menyerupainya. Ketiga, integrasi teknik interpretabilitas seperti peta aktivasi (misalnya Grad-CAM) dapat meningkatkan kepercayaan klinisi terhadap keluaran model. Keempat, validasi eksternal dan uji klinis prospektif diperlukan sebelum sistem benar-benar diterapkan dalam praktik nyata.

4. Conclusion

Penelitian ini memaparkan implementasi model deteksi dan segmentasi citra medis USG menggunakan YOLOv5 pada kasus hamil anggur (mola hidatidosa). Hasil eksperimen menunjukkan bahwa model mampu mengenali dan membedakan area yang mencurigakan pada citra USG dengan accuracy sebesar 90%, precision sebesar 93%, dan recall sebesar 94,6%. Keberhasilan model dalam mencapai keseimbangan optimal antara precision dan recall, sebagaimana tercermin pada kurva F1, menunjukkan bahwa pendekatan ini berpotensi besar meningkatkan ketepatan diagnosis hamil anggur. Dalam konteks inovasi bidang deteksi medis, YOLOv5 terbukti menjadi alat yang efektif untuk mempercepat proses identifikasi dan memberikan dampak positif pada praktik klinis. Namun demikian, penelitian ini juga mengidentifikasi beberapa aspek yang memerlukan perhatian lebih lanjut, seperti peningkatan kinerja model pada kasus yang kompleks, perluasan dan diversifikasi dataset, serta validasi klinis. Arah penelitian selanjutnya diharapkan dapat menyempurnakan model sehingga benar-benar siap dimanfaatkan sebagai alat bantu diagnosis di lingkungan klinis.

Acknowledgment

Penelitian ini didukung oleh Universitas Dinamika Bangsa, Jambi, Indonesia.

References

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015. DOI: 10.1038/nature14539
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017. DOI: 10.1145/3065386
- [3] G. Litjens, T. Kooi, B. E. Bejnordi, et al., "A Survey on Deep Learning in Medical Image Analysis," *Medical Image Analysis*, vol. 42, pp. 60-88, 2017. DOI: 10.1016/j.media.2017.07.005
- [4] D. Shen, G. Wu, and H.-I. Suk, "Deep Learning in Medical Image Analysis," *Annual Review of Biomedical Engineering*, vol. 19, pp. 221-248, 2017. DOI: 10.1146/annurev-bioeng-071516-044442
- [5] S. Liu, Y. Wang, X. Yang, et al., "Deep Learning in Medical Ultrasound Analysis: A Review," *Engineering*, vol. 5, no. 2, pp. 261-275, 2019. DOI: 10.1016/j.eng.2018.11.020

- [6] Y. Li, H. Gu, H. Wang, and P. Qin, "BUSnet: A Deep Learning Model of Breast Tumor Lesion Detection for Ultrasound Images," *Frontiers in Oncology*, vol. 12, art. 848271, 2022. DOI: 10.3389/fonc.2022.848271
- [7] O. A. Ajilisa, V. P. Jagathiraj, and M. K. Sabu, "Computer-Aided Diagnosis of Thyroid Nodule from Ultrasound Images Using Transfer Learning from Deep Convolutional Neural Network Models," in *Proc. 2020 Advanced Computing and Communication Technologies for High Performance Applications (ACCTHPA)*, 2020, pp. 237-241. DOI: 10.1109/ACCTHPA49271.2020.9213210
- [8] R. Girshick, "Fast R-CNN," in *Proc. 2015 IEEE International Conference on Computer Vision (ICCV)*, 2015, pp. 1440-1448. DOI: 10.1109/ICCV.2015.169
- [9] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137-1149, 2017. DOI: 10.1109/TPAMI.2016.2577031
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779-788. DOI: 10.1109/CVPR.2016.91
- [11] J. Redmon and A. Farhadi, "YOLO9000: Better, Faster, Stronger," in *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 6517-6525. DOI: 10.1109/CVPR.2017.690
- [12] 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," *Machine Learning and Knowledge Extraction*, vol. 5, no. 4, pp. 1680-1716, 2023. DOI: 10.3390/make5040083
- [13] S. Tan, G. Lu, Z. Jiang, and L. Huang, "Improved YOLOv5 Network Model and Application in Safety Helmet Detection," in *Proc. 2021 IEEE International Conference on Intelligence and Safety for Robotics (ISR)*, 2021, pp. 330-333. DOI: 10.1109/ISR50024.2021.9419561
- [14] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, LNCS vol. 9351, 2015, pp. 234-241. DOI: 10.1007/978-3-319-24574-4_28
- [15] M. Sokolova and G. Lapalme, "A Systematic Analysis of Performance Measures for Classification Tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427-437, 2009. DOI: 10.1016/j.ipm.2009.03.002


Authors' Profiles



Divia Nabilla Balqis lahir di Jambi, Indonesia. Saat ini sedang menempuh Program Sarjana Teknik Informatika di Universitas Dinamika Bangsa, Indonesia.



Dwi Setia Ningrum lahir di Jambi, Indonesia. Saat ini sedang menempuh Program Sarjana Teknik Informatika di Universitas Dinamika Bangsa, Indonesia.



Dwi Erna Septi Utami lahir di Jambi, Indonesia. Saat ini sedang menempuh Program Sarjana Teknik Informatika di Universitas Dinamika Bangsa, Indonesia.