

PEMANFAATAN SAM DAN YOLOV8 UNTUK DETEKSI DAN SEGMENTASI PADA CITRA MRI TUMOR OTAK

(UTILIZATION OF SAM AND YOLOV8 TO DETECTION AND SEGMENTATION OF BRAIN TUMOR ON MRI IMAGE)

Ardiansyah¹⁾, Krisna Nuresa Qodri²⁾, Dion Al Banna³⁾, dan Muhammad Zulfikhar Al-Baihaqi⁴⁾

^{1, 2,3,4)}Fakultas Kesehatan dan Teknologi Informasi, Universitas Muhammadiyah Klaten

Jl. Ir. Soekarno Km.1 Buntalan Klaten

e-mail: [^{1\)}ardiansyah@umkla.ac.id](mailto:ardiansyah@umkla.ac.id), [^{2\)}krisna@umkla.ac.id](mailto:krisna@umkla.ac.id), [^{3\)}dionalbanna07@gmail.com](mailto:dionalbanna07@gmail.com), [^{4\)}zulfialbaihaqi@gmail.com](mailto:zulfialbaihaqi@gmail.com)

ABSTRAK

Perkembangan kecerdasan buatan (AI) terkhusus untuk bidang Computer Vision (CV) yang bertujuan untuk mendapatkan informasi berdasarkan data yang terdapat pada media visual seperti gambar, video, ataupun lainnya. AI pada bidang kesehatan seperti pengenalan citra atau Deep Learning (DL) menjadi pembahasan yang sering dijadikan objek penelitian dan pengembangan. Keterbatasan di bidang kesehatan menjadi kemunculan pemanfaatan AI di bidang kesehatan sehingga mendorong penelitian DL dilakukan. Segmentation Anything Model (SAM) dan YOLOv8 merupakan algoritma baru yang diperkenalkan. Sehingga, penelitian ini bertujuan mengukur pemanfaatan SAM dan YOLOv8 untuk deteksi dan segmentasi pada data MRI Brain Tumor. Sebelum Proses training peneliti melakukan perbandingan segmentasi roboflow dan model SAM terlebih dahulu. Dataset dilabeling menggunakan Bounding Box oleh para ahli dari Hayatabad Medical Complex Peshawar. Dataset berisikan 455 glioma, 550 meningoma, 620 pituitary. Penelitian yang telah dilakukan menyimpulkan pemanfaatan SAM sangat mempermudah proses anotasi. YOLOv8 dengan task segmentasi mendapatkan hasil akurasi Box untuk semua kelas 86% presisi, 87% Recall, 89% mAP50 dan 71% mAP 50-95. Sedangkan evaluasi performa mask mendapatkan hasil 86% presisi, 87% Recall, 89% mAP50, dan 70% mAP50-95. Penelitian yang dilakukan mendapatkan model yang telah dilatih menggunakan YOLOv8n-seg mendapatkan hasil sangat baik meskipun merupakan model terkecil dari YOLOv8. Penelitian ini mendapatkan kelas tumor jenis glioma menjadi kelas dengan hasil yang terendah dikarenakan dataset yang digunakan tidak banyak. Disarankan untuk penelitian selanjutnya menggunakan data augmentasi untuk menambah penggunaan dataset setiap kelas. Sehingga memberikan hasil yang lebih baik.

Kata Kunci: YOLOv8, Instance Segmentation, MRI Tumor Otak, Segment Anything Model.

ABSTRACT

The development of artificial intelligence (AI) is specific to the field of Computer Vision (CV) to obtain information based on data contained in visual media. AI in the healthcare field such as image recognition and Deep Learning (DL) is a discussion that is often used as an object of research and development. The health sector Limitation is the emergence of AI utilization in the health sector, which encourages DL research. Segmentation Anything Model (SAM) and YOLOv8 are new algorithms introduced. Thus, this research aims to measure the utilization of SAM and YOLOv8 for making the detection and segmentation of Brain Tumor MRI data. Before the training process, researchers first compared roboflow segmentation and the SAM model. The dataset was labeled with a Bounding Box by experts. The dataset contains 455 gliomas, 550 meningiomas, and 620 pituitaries. The research concluded that the utilization of SAM greatly simplified the annotation process. The segmentation YOLOv8 obtained Box accuracy results for all classes of 86% precision, 87% Recall, 89% mAP50, and 71% mAP 50-95. The mask performance evaluation gets the results of 86% precision, 87% Recall, 89% mAP50, and 70% mAP50-95. The research obtained the YOLOv8n-seg model to get excellent results even though it is a tiny model of YOLOv8. This study found the glioma tumor class to be the class with the lowest results because the dataset used was not much. The researcher encourages other researchers to use data augmentation to increase the use of datasets for each class to provide better results.

Keywords: YOLOv8, Instance Segmentation, MRI Brain Tumor, Segment Anything Model.

I. PENDAHULUAN

Perkembangan kecerdasan buatan (AI) terkhusus untuk bidang Computer Vision (CV) yang bertujuan untuk mendapatkan informasi

berdasarkan data yang terdapat pada media visual seperti gambar, video, ataupun lainnya. Pemanfaatan AI sudah mencakup berbagai lini kehidupan guna meningkatkan produktifitas seperti pada bidang agrikultur [1] yang memanfaatkan deteksi objek menghitung buah [2], penyakit pada

tanaman kopi [3], bidang pendidikan menggunakan deteksi objek untuk mengenali tajwid [4]. Terkhusus bidang kesehatan yang menjadi pembahasan pro dan kontra [5], [6] terkait kecepatannya AI dalam berintegrasi di bidang kesehatan [7]. Hal tersebut sejalan dengan keterbatasannya dataset yang di terbitkan secara luas [8]. AI pada bidang kesehatan seperti pengenalan citra atau *Deep Learning* (DL) menjadi pembahasan yang sering dijadikan objek penelitian dan pengembangan [9].

Deteksi objek merupakan bagian dari CV yang digunakan untuk berbagai task yang bertujuan mendapatkan informasi berdasarkan gambar yang dijadikan sebuah objek [10]. Telah banyak pendekatan deteksi objek yang telah diperkenalkan seperti CNN, fast RCNN, dan *You Only Look Once* (YOLO) [10]. Tetapi, YOLO memiliki perbedaan diantar algorima CNN dan algoritma lainnya meskipun YOLO menggunakan arsitektur CNN juga. Sehingga, YOLO disebut algoritma yang memiliki tingkat akurasi lebih tinggi dan cepat dalam memberikan inference object detection sesuai dengan namanya YOLO [11].

Segment Anything Model (SAM) merupakan model yang dikembangkan oleh META untuk bidang CV segmentasi citra [12]. SAM model yang pada umumnya dilatih dengan data lebih dari 1 miliar mask sehingga dapat mengindentifikasi piksel yang menjadi objek. Kemunculan SAM bermula terinspirasi dari cabang bidang ilmu *Natural Language Processing* (NLP) yang memanfaatkan generalisasi *zero-shot* dan *few-shot* [13].

Deteksi objek sel darah putih menggunakan Yolov8 yang dihubungkan DETR teruji telah meningkatkan akurasi [14]. Penggunaan algoritma YOLOv8 yang di hubungkan dengan DETR mampu meningkatkan akurasi deteksi dibandingkan penggunaan YOLOv8 tanpa DETR sebesar 49% *basophils* dari 49%, 88% *lymphocytes* 2%, 63% *monocytes* 29%, 59% *eosinophils* 33%, and 81% *neutrophils* 3% [14].

Penelitian AI pada bidang kesehatan lainnya yang sering dijadikan objek penelitian adalah tumor pada otak menggunakan dataset *Magnetic Resonance Imaging* (MRI) [15]. Penelitian krisna dkk [16] mengklasifikasikan tumor otak menggunakan dataset 253 gambar dan DL sebagai metode klasifikasi tumor otak. Lebih spesifik DL yang digunakan pada penelitian tersebut adalah VGG16 dan ResNet50 mendapatkan kedua algoritma memiliki akurasi 96%.

Penelitian DL [17] terkait deteksi dan klasifikasi tumor otak dataset MRI membandingkan YOLOv5 model dan FastAi. Hasil pada penelitian yang telah dilakukan memberikan inference model FastAi lebih baik daripada YOLOv5 dengna hasil 95.78% berbanding 85.95%. Penelitian lainnya tentang tumor otak [18] menggunakan DL YOLOv8 dan pemanfaatan Augmentasi, dataset T1-weighted sebanyak 3064 gambar dengan kelas meningioma, glioma, dan pituitary. Dari penelitian tersebut berhasil mendapatkan hasil presisi 94%, recall 90%, mAP50 95%, mAP-95 73% secara keseluruhan.

Penelitian [19] pemanfaatan SAM untuk mengevaluasi segmentasi dari dataset tumor otak mendapatkan hasil yaitu: SAM mampu berkontribusi dalam labeling segmentasi namun dalam beberapa percobaan spesifik model tidak dapat berkerja dengan baik. SAM lebih efektif serta efisien dalam proses labeling tanpa menurunkan kualitas segmentasi. Kinerja SAM menjadi lebih baik terutama telah ditentukan batas area.

Penelitian [20] menggunakan YOLO-NAS dan SAM. SAM digunakan untuk membuat mask pada citra untuk menurunkan noise, perbaikan kecerahan citra, dan juga meningkatkan kualitas dataset yang digunakan. Penelitian ini memasukan SAM sebagai kontribusi penelitian dan juga memaparkan SAM menjadi topik yang perlu di improve untuk penelitian selanjutnya. Anotasi segmentasi sendiri menjadi terbatas dikarenakan proses segmentasi melabelin setiap piksel pada gambar [21] serta anotasi gambar MRI akan memakan waktu yang sangat banyak saat preprocessing [22].

Berdasarkan pemaparan diatas keterbatasan di bidang kesehatan menjadi kemunculan pemanfaatan AI di bidang kesehatan sehingga mendorong penelitian DL dilakukan. SAM dan YOLOv8 merupakan algoritma baru yang diperkenalkan. Sehingga, penelitian ini bertujuan mengukur pemanfaatan SAM dan YOLOv8 untuk deteksi dan segmentasi pada data MRI *Brain Tumor*.

II. STUDI PUSTAKA

Penelitian terkait tumor otak secara *real-time* yang memanfaatkan algoritma YOLO telah banyak dilakukan seperti penelitian [23] yang pada proses pelatihan data peneliti melakukan penambahan arsitektur CNN setelah proses klasifikasi atau deteksi objek menggunakan Yolov3. Penelitian tersebut mendapatkan hasil akurasi 97% dengan

binary class atau 2 kelas tumor *Low Grade Glioma* dan *High Grade Glioma*. Sehingga tidak dapat mengukur secara komprehensif bentuk tumor yang memiliki bentuk berbeda setiap kasus yang ditemukan.

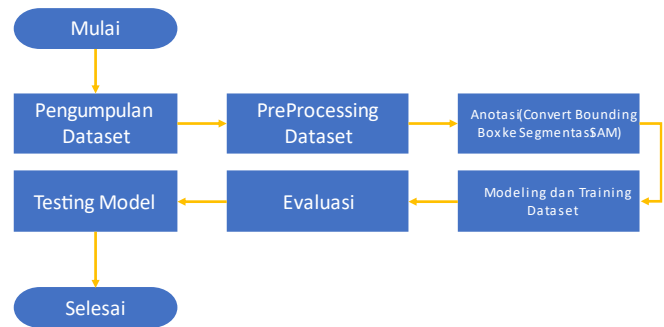
Penelitian [18] lainnya Yolov8 dan data augmentasi untuk memperbanyak dataset yang terbatas memperoleh evaluasi mendapatkan hasil untuk kelas *Meningioma* adalah 98% presisi, 95% recall, mAP50 98%, mAP50-95 84%. *Glioma* 89% presisi, 83% recall, 89% mAP50, mAP50-95 59%, *Pituitary* 95% presisi, 94% recall, the 97% mAP50, 75% mAP50-95. Perbedaan dengan penelitian yang dilakukan adalah proses preprocessing data penelitian dilakukan tanpa menggunakan augmentasi dataset namun yang dilakukan memanfaatkan segmentasi citra.

Penelitian [24] terkait tumor otak dan menggunakan Yolov8 mendapatkan hasil evaluasi penelitian mendapatkan hasil yang baik yaitu 97.6%. Penelitian tersebut yang dilakukan adalah menambahkan beberapa proses penggunaan SAM untuk mendapatkan hasil evaluasi yang lebih baik. Penelitian [24] menggunakan *Bounding Box* labeling beraskan hasil labeling peneliti berbeda. Sedangkan pada penelitian yang dilakukan memanfaatkan SAM untuk mengubah *Bounding Box* menjadi segmentasi objek pada area *Bounding Box* meskipun memiliki kesamaan memanfaatkan labeling peneliti berbeda.

Penelitian [25] mengungkapkan bahwa SAM memiliki beberapa faktor untuk mendapatkan hasil yang maksimal yaitu: penggunaan dataset yang berasal dari visual 2D, 3D, dermoscopy, colonoscopy, X-ray. Dataset MRI sendiri termaksud dalam visual 3D dengan kualitas tinggi yang mampu merepresentasikan bagian tubuh [26], [27]. Segmentasi gambar menggunakan DL menjadi teknik yang akurat dalam mendeteksi tumor otak secara konvensional maupun informatif [28].

III. METODE PENELITIAN

Pada penelitian yang dilakukan seperti Gambar 1 berikut.



Gambar 1. Alur Penelitian

Gambar 1 merepresentasikan alur dari penelitian yang dilakukan diawali dengan pengumpulan dataset yang dimana dilakukan dari dataset publik. Langkah kedua yaitu *pre-processing dataset* pada penelitian dilakukan mengubah semua gambar menjadi ukuran 640x640 serta pembagian dataset menjadi 3 bagian (train, validasi dan test). Langkah ketiga *convert bounding box* ke segmentasi menggunakan roboflow. Langkah keempat dan kelima yang dilakukan peneliti adalah melatih dataset yang telah disegmentasi pada tahap sebelumnya serta mengevaluasi model saat train dataset. Langkah terakhir adalah melatih model yang telah dilatih dengan *dataset test*.


A. Metode Pengumpulan Data

Pengumpulan dataset dari *kaggle* sebagai dataset publik [29] yang telah dilabeling menggunakan bounding box oleh para ahli dari *Hayatabad Medical Complex Peshawar*. Dataset berisikan 455 *glioma*, 550 *meningoma*, 620 *pituitary*. Seluruh dataset yang dikumpulkan bertipe jpg. Dataset yang dikumpulkan memiliki perbedaan ukuran gambar setiap kelas nya sehingga perlu dilakukan preprocessing data gambar untuk memaksimalkan kinerja dari model ketika pelatihan data berlangsung serta meminimalisir penggunaan daya *machine* yang terbatas. Persebaran ukuran pada dataset seperti yang terlihat pada Gambar 2.

Dimension Insights

Size Distribution

The **purple box** indicates the median width by median height image (512x512).



Gambar 2. Persebaran ukuran gambar pada dataset

Berdasarkan gambar 2 dapat dilihat bahwa awal mula dataset yang diperoleh masih terdapat gambar dengan ukuran jumbo atau lebih besar dari 1024 x 1024. Sehingga akan dilakukan proses penyesuaian gambar pada tahapan *preprocessing* data.


B. Preprocessing Data

Gambar 2 merepresentasikan ukuran citra pada dataset yang dikumpulkan memiliki ukuran berbeda-beda. Sehingga perlu untuk dilakukan penyesuaian ukuran untuk semua gambar menjadi 640x640 tanpa terkecuali yang menggunakan fitur pada *roboflow*. Selain itu, kualitas gambar MRI tumor otak yang buram atau rusak akan dihapus dari dataset yang telah dikumpulkan. Pada proses preprocessing dataset juga dilakukan pembagian data dengan rasio 70:20:10 atau sebanyak 1126 gambar train, 320 gambar validasi, dan 161 gambar test.

C. SAM dan YOLOv8

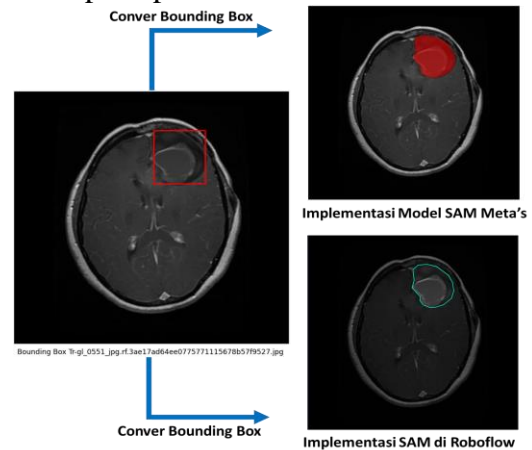
Segment Anything Model (SAM) pada dasarnya memiliki 3 komponen yaitu *Encoder Gambar* yang menggunakan *VisionTransformer* (ViT) yang telah dilatih sebelumnya untuk mengelola resolusi yang tinggi, *Flexible Prompt Encoder* komponen yang mempertimbangkan jarak dan mask dari gambar, dan *Fast Mask Decoder* komponen bertujuan untuk membuat mask berdasarkan *Flexible Prompt Encoder* yang dimana mempertimbangkan jarak

dari sebuah titik, kotak, ataupun teks. SAM dapat direpresentasikan seperti yang terlihat pada Gambar 3 [13].



Gambar 3. Gambar sekilas Model Segment Anything

Implementasi SAM di *roboflow* dapat dilakukan menggunakan *Polygon* anotasi maupun *Smart Polygon* untuk mempermudah dalam Anotasi atau labeling objek [30]. Berikut Gambar 4 anotasi yang dilakukan pada penelitian.



Gambar 4. SAM model pada dataset penelitian

Sebelum melakukan proses training peneliti melakukan perbandingan segmentasi roboflow dan model SAM terlebih dahulu. Gambar 4 merepresentasikan SAM robotflow telah sesuai dengan model SAM aslinya.

YOLOv8 merupakan model *Computer Vision* yang seringkali dimanfaatkan industri untuk robotik, *Self-Driving*. YOLOV8 dapat mengidentifikasi sebuah objek secara real-time. YOLOv8 framework memiliki beberapa task yang bekerja dengan baik seperti deteksi objek, *Instance* segmentasi, klasifikasi objek, dan *Pose Estimation*. Kebaharuan YOLOv8 memiliki beberapa titik penting yaitu: Arsitektur *Backbone* dan *Neck* lanjutan, memanfaatkan *achor-free split ultralytics head* untuk mendapatkan akurasi yang baik berdasarkan proses deteksi yang efisien, kecepatan dalam deteksi objek dengan mempertimbangkan akurasi, dan model pre-trained yang sudah sangat banyak untuk task khusus. Berikut Tabel 1 perbedaan model YOLOv8 untuk task *Instance* segmentasi [31], [32].


Tabel 1. Performa model *Instance Segmentation* YOLOv8

| Model | mAP 50-95 | | Speed A100 (ms) | Params (M) | FLOPs (B) |
|-------------|-----------|------|-----------------------|---------------|--------------|
| | box | Mask | | | |
| YOLOv8n-seg | 36.7 | 30.5 | 1.21 | 3.4 | 12.6 |
| YOLOv8s-seg | 44.6 | 36.8 | 1.47 | 11.8 | 42.6 |
| YOLOv8m-seg | 49.9 | 40.8 | 2.18 | 27.3 | 110.2 |
| YOLOv8l-seg | 52.3 | 42.6 | 2.79 | 46.0 | 220.5 |
| YOLOv8x-seg | 53.4 | 43.4 | 4.02 | 71.8 | 344.1 |

Instance Segmentation merupakan kombinasi dari semantic segmentasi dan deteksi objek. *Instance segmentation* bertujuan untuk memprediksi kelas yang terdapat pada objek dan mask yang memanfaatkan spesifikasi pixel yang berada pada gambar. Pada *Instance Segmentation* memanfaatkan *Bounding box* untuk membatasi objek yang akan di segmentasi [33], [34].

D. Anotasi

Anotasi tahapan untuk merepresentasikan Ground Truth objek pada gambar [3]. Anotasi pada penelitian yang dilakukan memanfaatkan roboflow. Peneliti melakukan perubahan *Bounding Box* yang telah dilabelin oleh para ahli sebelumnya [29] menjadi *Instance Segmentation* yang memanfaatkan model SAM. Berikut Gambar 5 perubahan *Bounding Box* ke *Instance Segmentation* di setiap kelas.



Gambar 5. Perubahan *Bounding Box* ke *Instance Segmentation* menggunakan roboflow

E. Evaluasi Model

Evaluasi model instance segmentasi yang digunakan untuk mengukur kesalahan *Ground Truth* dan *Predict Segmentation* atau yang sering disebut *Intersection over Union* (IoU) [32].

Selanjutnya, *Confusion Matrix* evaluasi model secara komprehensif sehingga dapat merepresentasikan kinerja pelatihan model. *Confusion Matrix* didapatkan berdasarkan perhitungan menggunakan persamaan (1), (2), (3), (4) sebagai berikut:

$$precision = \frac{TP}{TP+FP} \quad (1)$$

$$recall = \frac{TP}{TP+FN} \quad (2)$$

$$AP = \int_0^1 p(R) dR \quad (3)$$

$$mAP = \frac{\sum_m AP}{m} \quad (4)$$


TP merupakan *True Positive*, FP merupakan *False Positive*, FN merupakan *False Negative*, AP merupakan *Average Precision*, mAP merupakan *mean Average Precision*. Presisi digunakan untuk mendapatkan seberapa akuratnya model memprediksi dengan benar. Recall digunakan untuk mengukur presentasi label terkait yang berhasil di predict atau di identifikasi.

IV. HASIL DAN PEMBAHASAN

Kebutuhan minimal dalam training data dapat dilakukan menggunakan T4 GPU. Penelitian yang dilakukan menggunakan Google Colab Pro dengan spesifikasi torch-2.1.0+cu121, *Graphical Processing Unit* (GPU) Tesla V100-SXM2-16GB, 16151MiB untuk komputasi model YOLOv8n-seg. Peneliti menggunakan GPU V100 dikarenakan batas proses komputasi lebih banyak dibandingkan T4.

A. Pelatihan Dataset

Pelatihan dataset dilakukan setelah proses preprocessing selesai dilakukan serta perubahan *Bounding Box* ke *Instance Segmentation* menggunakan roboflow. Tahapan perubahan ke segmentasi menghasilkan anotasi heatmap setiap kelas seperti pada Gambar 6.



Gambar 6. Anotasi heatmap setiap kelas

Gambar 6 merepresentasikan mask pada setiap kelas memiliki bentuk yang berbeda beda. Sehingga dengan ada nya anotasi heatmap memudahkan untuk mengenali bentuk bentuk setiap kelas.

Proses pelatihan dataset pada penelitian yang dilakukan menggunakan hyperpmeter task segment, 200 epochs, 4 batch, imgsz 640, optimizer AdamW dengan *learning rate* 0.001429 serta 0.9 *momentum*, *patience* 0. Model yang digunakan yolov8n-seg yang dimana memiliki proses train yang cepat dan merupakan model yang terkecil dibandingkan model segmentasi lainnya yang disediakan YOLOv8.

B. Evaluasi Model


Evaluasi model yang dihasilkan berdasarkan proses pelatihan dataset seperti pada Tabel 2 evaluasi performa box dan Tabel 3 evaluasi performa mask pada model. Sedangkan Gambar 7 merupakan hasil evaluasi yang didapatkan berdasarkan perhitungan menggunakan persamaan (1), (2), (3), (4).

Tabel 2. Evaluasi perfoma Box model

| Class | Images | | Box | | | |
|---------------|---------------|------|------|-----------|--------------|--|
| | Instanc es | P | R | mAP 50 | mAP5 0-95 | |
| All | 320 | 0.86 | 0.87 | 0.899 | 0.718 | |
| | 323 | 7 | 8 | | | |
| Glioma | 320 | 0.71 | 0.69 | 0.69 | 0.495 | |
| | 92 | 7 | | | | |
| Meningo ma | 320 | 0.96 | 0.98 | 0.986 | 0.863 | |
| | 107 | 3 | 6 | | | |
| Pituitary | 320 | 0.92 | 0.96 | 0.96 | 0.797 | |
| | 124 | 2 | | | | |


Tabel 3. Evaluasi perfoma Mask model

| Class | Images | | Mask | | | |
|---------------|---------------|------|------|-----------|--------------|--|
| | Instanc es | P | R | mAP 50 | mAP5 0-95 | |
| All | 320 | 0.86 | 0.87 | 0.897 | 0.709 | |
| | 323 | 4 | 5 | | | |
| Glioma | 320 | 0.70 | 0.67 | 0.72 | 0.478 | |
| | 92 | 6 | 9 | | | |
| Meningo ma | 320 | 0.96 | 0.96 | 0.987 | 0.868 | |
| | 107 | 3 | 3 | | | |
| Pituitary | 320 | 0.92 | 0.96 | 0.983 | 0.782 | |
| | 124 | 1 | | | | |



Gambar 7. Evaluasi *Confusion Matrix*

Selain *Confusion Matrix*, evaluasi model juga terdapat *F1-confidence* yang dimana pada penelitian menggunakan box dan mask seperti yang terlihat pada Gambar 8. *F1-Confidence* merepresentasikan keseimbangan yang mempertimbangkan nilai *False Negative* dan *False Positive*.

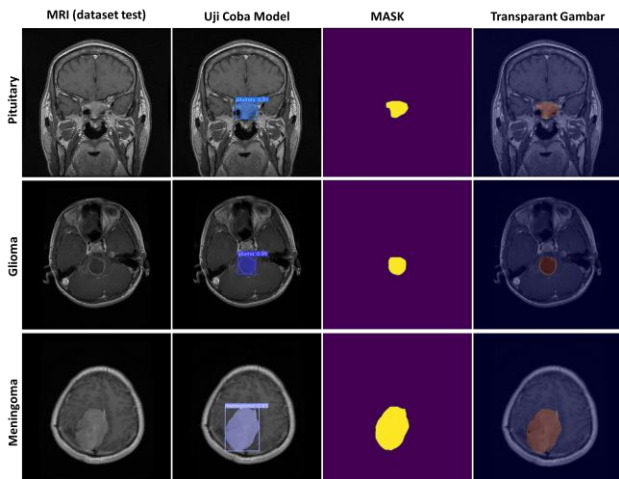


Gambar 8. *F1-Confidence* untuk Box (a), Mask (b)

Gambar 8 memberikan hasil F1-Confidence untuk box dan mask pada semua kelas 0.87 at 0.226 yang berarti model mendapatkan hasil presisi 87% dengan ambang batas kepercayaan 0.226.

C. Uji Coba Model

Uji coba model dilakukan pada penelitian yang dilakukan menggunakan model hasil dari latih data yang telah dilakukan. model hasil train di uji coba dengan data test sesuai dengan yang telah dijelaskan pada bagian preprocessing data. Uji coba model yang dilakukan mendapatkan hasil seperti yang terlihat pada Gambar 9.



Gambar 9. Hasil uji coba model pada data test

Gambar 9 menjelaskan model yang telah dilatih mendapatkan hasil untuk kelas 91% Pituitary, 95% Glioma, 93% Meningioma pada percobaan deteksi objek.

V. KESIMPULAN

Penelitian yang telah dilakukan menyimpulkan pemanfaatan SAM sangat mempermudah proses anotasi. Meskipun begitu, model SAM dari Meta's masih memiliki keterbatasan dalam anotasi masih perlu improve seperti yang dilakukan roboflow dalam pengimplementasian. Hal tersebut telah dilakukan peneliti dan ditunjukkan pada Gambar 4. SAM model memerlukan parameter batasan menggunakan *Bounding Box* untuk menentukan segmentasi. Yang dimana memerlukan keahlian khusus untuk penentuan kelas sebuah objek.

YOLOv8 dengan task segmentasi mendapatkan hasil akurasi *Box* untuk semua kelas 86% presisi, 87% Recall, 89% mAP50 dan 71% mAP 50-95. Sedangkan evaluasi performa mask mendapatkan hasil 86% presisi, 87% Recall, 89% mAP50, dan 70% mAP50-95. Penelitian yang dilakukan mendapatkan model yang telah dilatih menggunakan YOLOv8n-seg mendapatkan hasil sangat baik meskipun merupakan model terkecil dari YOLOv8.

Penelitian ini mendapatkan kelas tumor jenis glioma menjadi kelas dengan hasil yang terendah dikarenakan dataset yang digunakan tidak banyak. Disarankan untuk penelitian selanjutnya menggunakan data augmentasi untuk menambah penggunaan dataset setiap kelas. Sehingga memberikan hasil yang lebih baik.

UCAPAN TERIMA KASIH

Terima kasih kepada Universitas Muhammadiyah yang telah mendukung penelitian

ini sehingga dapat terlaksanakan.

DAFTAR PUSTAKA

- [1] O. Wosner, G. Farjon, and A. Bar-Hillel, "Object detection in agricultural contexts: A multiple resolution benchmark and comparison to human," *Comput Electron Agric*, vol. 189, p. 106404, 2021.
- [2] A. I. B. Parico and T. Ahamed, "Real time pear fruit detection and counting using YOLOv4 models and deep SORT," *Sensors*, vol. 21, no. 14, p. 4803, 2021.
- [3] A. Ardiansyah and N. F. Hasan, "Deteksi dan Klasifikasi Penyakit Pada Daun Kopi Menggunakan YOLOv7," *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, vol. 12, no. 1, pp. 30–35, 2023.
- [4] D. I. Mulyana and M. A. I. Rowis, "Optimization of Text Mining Detection of Tajweed Reading Laws Using the YOLOv8 Method on the Qur'an," *QALAMUNA: Jurnal Pendidikan, Sosial, dan Agama*, vol. 14, no. 2, pp. 1089–1110, 2022.
- [5] A. J. London, "Artificial intelligence in medicine: Overcoming or recapitulating structural challenges to improving patient care?," *Cell Rep Med*, vol. 3, no. 5, 2022.
- [6] S. Reddy, "Explainability and artificial intelligence in medicine," *Lancet Digit Health*, vol. 4, no. 4, pp. e214–e215, 2022.
- [7] R. B. Parikh and L. A. Helmchen, "Paying for artificial intelligence in medicine," *NPJ Digit Med*, vol. 5, no. 1, p. 63, 2022.
- [8] D. W. Putranto, Andi Sunyoto, and Asro Nasiri, "PEMANFAATAN DEEP LEARNING UNTUK SEGMENTASI PARU-PARU DARI CITRA X-RAY DADA," *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 4, no. 2, pp. 144–150, Dec. 2023, doi: 10.46764/teknimedia.v4i2.114.
- [9] J. G. M. Esgario, R. A. Krohling, and J. A. Ventura, "Deep learning for classification and severity estimation of coffee leaf biotic stress," *Comput Electron Agric*, vol. 169, Feb. 2020, doi: 10.1016/j.compag.2019.105162.
- [10] S. Lu, B. Wang, H. Wang, L. Chen, M. Linjian, and X. Zhang, "A real-time object detection algorithm for video," *Computers & Electrical Engineering*, vol. 77, pp. 398–408, 2019.
- [11] W. Fang, L. Wang, and P. Ren, "Tinier-YOLO: A real-time object detection method for constrained environments," *IEEE Access*, vol. 8, pp. 1935–1944, 2019.
- [12] I. Giannakis, A. Bhardwaj, L. Sam, and G. Leontidis, "A flexible deep learning crater detection scheme using Segment Anything Model (SAM)," *Icarus*, vol. 408, Jan. 2024, doi: 10.1016/j.icarus.2023.115797.
- [13] A. Kirillov *et al.*, "Segment anything," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2023, pp. 4015–4026.
- [14] S. J. A. Nugraha and B. Erfianto, "White Blood Cell Detection Using YOLOv8 Integration with DETR to Improve Accuracy," *Sinkron: jurnal dan penelitian teknik informatika*, vol. 8, no. 3, pp. 1908–1916, 2023.

- [15] D. M. Toufiq, A. M. Sagheer, and H. Veisi, "Brain tumor identification with a hybrid feature extraction method based on discrete wavelet transform and principle component analysis," *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 5, pp. 2588–2597, 2021.
- [16] K. N. Qodri, I. Soesanti, and H. A. Nugroho, "Image analysis for MRI-based brain tumor classification using deep learning," *IJITEE (International Journal of Information Technology and Electrical Engineering)*, vol. 5, no. 1, pp. 21–28, 2021.
- [17] N. M. Dipu, S. A. Shohan, and K. M. A. Salam, "Deep learning based brain tumor detection and classification," in *2021 International conference on intelligent technologies (CONIT)*, IEEE, 2021, pp. 1–6.
- [18] R. S. Passa, S. Nurmaini, and D. P. Rini, "YOLOv8 Based on Data Augmentation for MRI Brain Tumor Detection," *Scientific Journal of Informatics*, vol. 10, no. 3, 2023.
- [19] Y. Huang *et al.*, "Segment anything model for medical images?," *Med Image Anal*, vol. 92, Feb. 2024, doi: 10.1016/j.media.2023.103061.
- [20] M. N. Sharma, "IMAGE AND VIDEO SEGMENTATION USING YOLO-NAS AND SEGMENT ANYTHING MODEL (SAM): MACHINE LEARNING," *International Research Journal of Modernization in Engineering Technology and Science*, vol. 05, no. 10, 2023.
- [21] Y. Liu, Y.-H. Wu, P. Wen, Y. Shi, Y. Qiu, and M.-M. Cheng, "Leveraging Instance-, Image- and Dataset-Level Information for Weakly Supervised Instance Segmentation," *IEEE Trans Pattern Anal Mach Intell*, vol. 44, no. 3, pp. 1415–1428, Mar. 2022, doi: 10.1109/TPAMI.2020.3023152.
- [22] A. Kumar, "Study and analysis of different segmentation methods for brain tumor MRI application," *Multimed Tools Appl*, vol. 82, no. 5, pp. 7117–7139, Feb. 2023, doi: 10.1007/s11042-022-13636-y.
- [23] M. M. Chanu, N. H. Singh, C. Muppala, R. T. Prabu, N. P. Singh, and K. Thongam, "Computer-aided detection and classification of brain tumor using YOLOv3 and deep learning," *Soft comput*, vol. 27, no. 14, pp. 9927–9940, 2023.
- [24] B. Selcuk and T. Serif, "Brain Tumor Detection and Localization with YOLOv8," in *2023 8th International Conference on Computer Science and Engineering (UBMK)*, IEEE, 2023, pp. 477–481.
- [25] S. He *et al.*, "Computer-vision benchmark segment-anything model (sam) in medical images: Accuracy in 12 datasets," *arXiv preprint arXiv:2304.09324*, vol. 3, 2023.
- [26] S. Sarker, A. Biswas, N. M. A. Al, M. S. Ali, S. Puppala, and S. Talukder, "Case Studies on X-ray Imaging, MRI and Nuclear Imaging," *Data Driven Approaches on Medical Imaging*, pp. 207–225, 2023.
- [27] K. Priyadharshini, P. Krishnamoorthy, B. S. Ganapathy N, K. Karthikeyan, U. M. S, and R. Peddaveni, "Artificial Intelligence Assisted Improved Design to Predict Brain Tumor on Earlier Stages using Deep Learning Principle," in *2023 Annual International Conference on Emerging Research Areas: International Conference on Intelligent Systems (AICERA/ICIS)*, IEEE, Nov. 2023, pp. 1–6. doi: 10.1109/AICERA/ICIS59538.2023.10420011.
- [28] T. A. Soomro *et al.*, "Image Segmentation for MR Brain Tumor Detection Using Machine Learning: A Review," *IEEE Rev Biomed Eng*, vol. 16, pp. 70–90, 2023, doi: 10.1109/RBME.2022.3185292.
- [29] A. Ahmed and K. M. Hamza, "Labeled MRI brain Tumor dataset," Kaggel. Accessed: Feb. 14, 2024. [Online]. Available: <https://www.kaggle.com/datasets/ammarahmed310/labeled-mri-brain-tumor-dataset>
- [30] P. Skalski, "How to Use the Segment Anything Model (SAM). Roboflow Blog," roboflow. Accessed: Mar. 14, 2024. [Online]. Available: <https://blog.roboflow.com/how-to-use-segment-anything-model-sam/>
- [31] G. Jocher, A. Chaurasia, and J. Qiu, "Ultralytics YOLOv8." 2023. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [32] R. Bai, M. Wang, Z. Zhang, J. Lu, and F. Shen, "Automated Construction Site Monitoring Based on Improved YOLOv8-seg Instance Segmentation Algorithm," *IEEE Access*, vol. 11, pp. 139082–139096, 2023, doi: 10.1109/ACCESS.2023.3340895.
- [33] B. Gouila, "Instance Segmentation for Rock Particle Quality Monitoring: Integration of Deep Learning for Machine Vision Application in the Aggregates Industry," 2024.
- [34] A. M. Hafiz and G. M. Bhat, "A survey on instance segmentation: state of the art," *Int J Multimed Inf Retr*, vol. 9, no. 3, pp. 171–189, Sep. 2020, doi: 10.1007/s13735-020-00195-x.