

Implementasi Deteksi Tumor Otak Menggunakan YOLOv11 dan Flask

Ardiansyah^{1*}, Adika Sri Widagdo², Krisna Nuresa Qodri³, Diesti Hidayani⁴, Mustofa Romadhani⁵

^{1,2,3,4,5}Teknologi Informasi, Fakultas Kesehatan dan Teknologi, Universitas Muhammadiyah Klaten

¹Ardiansyah@umkla.ac.id*, ²adikasw@umkla.ac.id, ³krisna@umkla.ac.id, ⁴diestihidayani@gmail.com,

⁵Mustofaramadhani415@gmail.com

Abstract

Artificial intelligence (AI) has made significant progress in helping people's lives, one of which is in the health field. The advancement of AI is driven by numerous errors caused by fundamental factors and the high demand from the public for healthcare services, which continues to increase. AI can also minimize diagnostic and treatment errors in clinical practice, such as brain tumor detection. The YOLO algorithm is frequently used for object detection due to its high accuracy. YOLO can also be utilized for real-time diagnosis, adding value to the algorithm. YOLOv11 is the latest algorithm and performs better than its predecessors. However, the challenge of limited datasets remains an issue that needs to be addressed. Therefore, this study aims to increase the number of medical image datasets using Data Augmentation and integrate the YOLO algorithm with Flask to provide a better display for users. The research used Data Augmentation on the dataset using the Flip technique (Horizontal and Vertical), 90° Rotate (Clockwise, Counter-Clockwise, Upside Down), and the addition of Noise: Up to 1.5% of pixels. As a result, an F1-score of 0.951 was obtained from 4 classes (0.902 Glioma, 0.989 Meningioma, 0.915 Pituitary, and 0.997 No tumor). It proves to be effective in overcoming data limitations. Furthermore, integrating YOLO with Flask can provide better object detection display without lowering the brain tumor object detection results score. Thus, Flask can be considered a machine learning interface development framework.

Keywords: brain tumor MRI, data augmentation, flask, yolov11, deep learning

Abstrak

Kecerdasan buatan (AI) telah mengalami kemajuan yang sangat signifikan untuk membantu kehidupan masyarakat salah satunya adalah bidang kesehatan. Kemajuan AI didorong karena banyaknya kesalahan yang diakibatkan beberapa faktor fundamental dan tingginya permintaan dari masyarakat terhadap layanan kesehatan terus meningkat. AI juga mampu meminimalkan kesalahan diagnosa maupun pengobatan dalam praktik klinis pasien seperti deteksi tumor otak. Algoritma YOLO yang sering digunakan untuk deteksi objek karena akurasi yang tinggi. YOLO juga dapat digunakan untuk real-time diagnosa menjadi nilai tambah pada algoritma tersebut. YOLOv11 merupakan algoritma terbaru dan memiliki performa yang lebih baik dibandingkan seri sebelumnya. Meskipun begitu, tantangan terhadap keterbatasan dataset menjadi salah satu permasalahan yang perlu diselesaikan. Penelitian yang dilakukan memiliki tujuan yaitu meningkatkan jumlah dataset citra medis menggunakan Data Augmentasi dan mengintegrasikan algoritma YOLO dengan Flask untuk memberikan tampilan yang lebih baik kepada pengguna. Penelitian yang dilakukan menggunakan Data Augmentasi pada dataset menggunakan teknik *Flip (Horizontal dan Vertical)*, *90° Rotate (Clockwise, Counter-Clockwise, Upside Down)*, serta penambahan *Noise: Up to 1.5% of pixels*. Hasilnya, diperoleh *F1-score* 0.951 dari 4 kelas (0.902 Glioma, 0.989 Meningioma, 0.915 Pituitary, dan 0.997 No tumor). Sehingga terbukti efektif mengatasi keterbatasan data. Selanjutnya, Integrasi YOLO dengan Flask dapat memberikan tampilan deteksi objek yang lebih baik tanpa menurunkan skor dari hasil deteksi objek tumor otak, sehingga Flask dapat dijadikan *framework* yang dipertimbangkan untuk pengembangan *interface machine learning*.

Kata kunci: data augmentasi, flask, yolov11, MRI tumor otak, *deep learning*

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

1. Pendahuluan

Kecerdasan buatan (AI) telah mengalami kemajuan yang sangat signifikan untuk membantu kehidupan masyarakat. AI menawarkan peningkatan produktifitas diberbagai bidang salah satunya adalah bidang kesehatan [1], [2]. Meskipun bidang kesehatan yang telah memanfaatkan AI sebagai alat bantu, masih sering terjadi perbedaan pendapat. Masih banyak yang pro dan kontra dalam keterlibatan AI dalam bidang

kesehatan [3], [4]. Selain itu, terdapat beberapa hal yang menjadi tantangan AI dalam bidang kesehatan antara lain: etika dan privasi, kesadaran kemajuan AI, tingkat kepercayaan terhadap AI, dan profesionalisme dalam bidang kesehatan [5], [6]. Salah satu resiko yang dikhawatirkan adalah tereliminasi *stakeholder* oleh AI karena ketidakmampuan *stakeholder* meningkatkan kemampuan mereka sendiri [7].

Lebih jauh tentang kemajuan AI didorong karena banyaknya kesalahan yang diakibatkan beberapa faktor fundamental dan tingginya permintaan dari masyarakat terhadap layanan kesehatan terus meningkat. Dilain sisi ketersediaan tenaga medis tidak dapat memenuhi permintaan tersebut [5]. AI juga mampu meminimalkan kesalahan diagnosa maupun pengobatan dalam praktik klinis pasien. Hal tersebut dikarenakan AI berbeda dengan pendekatan konvensional. AI menggunakan data lampau seperti pengalaman *Profiling* sebagai dasar memberikan rekomendasi [5], [8].

AI memiliki beberapa task atau tugas yang sering digunakan dalam bidang kesehatan antara lain: deteksi, prediksi, penilaian, prognosis, maupun klasifikasi [6], [9]. Fungsi tersebut seringkali di implementasikan pada penyakit kanker antara lain: kanker paru-paru, kanker payudara, kanker serviks, kanker lambung, kanker otak dan beberapa jenis kanker lainnya [9]. Meskipun AI mampu melakukan tugas tersebut berapa hal yang sangat perlu diperhatikan antara lain akurasi, efektifitas pembiayaan, dan kecepatan yang menjadi tantangan dalam *Early Detection Diseases* [8], [10]. Terkhusus untuk deteksi objek tumor otak, *Magnetic Resonance Imaging* (MRI) menjadi citra yang lebih disukai *stakeholder* dibandingkan *Computed Tomography* (CT) scan. Hal tersebut dikarenakan MRI tidak menghasilkan radiasi pengion. Selain itu MRI mempunyai kontras yang lebih baik sehingga mampu memberikan perbedaan citra, antara jaringan otak normal dengan otak yang terkena penyakit kanker. Perbedaan kontras tersebut dapat mempermudah diagnosis yang lebih akurat [11], [12].

Central Nervous System (CNS) berdasarkan laporan GLOBACAN pada Tahun 2022, memperkirakan terdapat kasus tumor otak yang mencapai 322.000 kasus dan akan meningkat 47% atau 474.000 kasus baru di tahun 2045. Selain itu, ditemukan juga wilayah yang memiliki kasus tertinggi antara lain: Amerika Utara (5.46), Asia Timur (3.95), dan Eropa Barat (5.56). Sementara itu Afrika menjadi wilayah dengan tingkat kasus lebih rendah [13]. Selama kurang lebih 5 dekade, pemecahan masalah pada bidang kesehatan menggunakan AI seringkali menggunakan seperti *Deep learning* (DL) dan *Machine Learning* (ML). DL telah teruji mampu meningkatkan akurasi diagnosa, efisiensi alur kerja maupun operasional klinik [14]. Algoritma DL dengan tugas deteksi objek seperti *Convolution Neural Network* (CNN), *Fast CNN*, maupun *You Only Look Once* (YOLO) [15], [16]. Algoritma YOLO pada dasarnya menggunakan CNN sebagai arsitektur dasarnya, namun YOLO dirancang dengan tujuan penggunaan deteksi objek secara *real-time* [17], [18], [19], [20].

Penelitian [1] menggunakan *Segmentation Anything Model* (SAM) dan YOLOv8 bertujuan untuk segmentasi tumor otak pada gambar MRI. Penelitian tersebut mendapatkan hasil untuk semua kelas yang digunakan adalah 86% presisi, 87% recall, 89% mAP

50 dan 71% mAP50-95. Penelitian [1] juga menggunakan *dataset* publik dikarenakan terbatasnya *dataset* yang dapat diakses secara umum. Penelitian [21] serupa, membandingkan YOLOv8 dan SAM. Keduanya mampu memberikan hasil deteksi objek yang baik. Namun, berdasarkan kedua penelitian tersebut mendapatkan tantangan yang sama terkait terbatasnya akses *dataset* seperti pada bidang kesehatan [22]. Selain itu, pada penelitian [21] menyatakan SAM perlu mempertimbangkan adanya tambahan pembiayaan dalam proses pelatihan maupun prediksi.

Penelitian [23] yang juga menggunakan YOLOv8 untuk deteksi objek tumor otak pada Citra MRI mendapatkan hasil 94% presisi, 90% *recall*, 95% mAP. Penelitian tersebut menggunakan Data Augmentasi untuk menangani keterbatasan *dataset*. Augmentasi yang digunakan antara lain: *Flip Horizontal*, 90 derajat rotasi citra searah jam maupun sebaliknya, *Crop* maksimal 20%, Rotasi dalam rentan -15 derajat sampai 15 derajat, *Shear* 15 derajat horizontal dan vertikal, *grayscale* sampai 25%, *brightness* antara -40 derajat sampai +40 derajat, *exposure* antara -25% sampai +25%, *blur* sampai 2.5 piksel, dan *noise* 10% dari setiap piksel citra.

Penelitian [16] menggunakan YOLOv11 mendapatkan hasil lebih baik dibandingkan dengan algoritma Faster RCNN dan SSD terhadap objek retak tulang pada Citra X-Ray. YOLOv11 berhasil mendapatkan nilai mAP 96.8% dan *Intersection of Union* (IoU) 92.5%.

Berdasarkan latar belakang yang telah dipaparkan, berikut permasalahan yang menjadi fokus pada penelitian antara lain: Pemanfaatan serta integrasi algoritma YOLO dengan Flask, serta peningkatan *dataset* citra medis yang menjadi masalah utama dalam pelatihan data pada bidang kesehatan.

2. Metode Penelitian

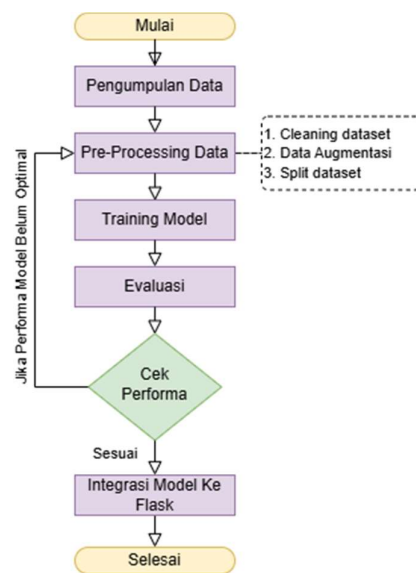
Berikut Gambar 1 merupakan tahapan penelitian yang dilakukan. Tahapan awal yang dilakukan pada penelitian yaitu: pengumpulan data MRI tumor otak yang memanfaatkan kumpulan data publik [24]. langkah berikutnya setelah data telah terkumpul adalah *pre-processing dataset*, langkah tersebut dilakukan *cleaning dataset*, data augmentasi, dan *splitting dataset*. Setelahnya, *dataset* yang telah melalui proses *pre-processing* akan dilatih dengan model YOLO serta akan di evaluasi kinerja model. Jika mendapatkan hasil akurasi yang baik maka akan dilakukan integrasi model dengan Flask. Namun, jika ditemukan mAP, *precision*, atau *recall* rendah, maka akan dilakukan perbaikan *dataset* dengan proses awal yaitu augmentasi dan perbaikan *hypermeter* seperti penyesuaian *learning rate*, *batch size*, jumlah *epochs*, *optimizer*.

2.1. Penelitian Terkait

Hasil penelitian [25] yang didapatkan YOLO tidak mendapatkan hasil maksimal dibandingkan dengan

FastAi. Sehingga Perlu dilakukan untuk eksplorasi YOLO dengan versi terbaru. Dalam penelitian yang dilakukan akan menggunakan YOLOv11 *task object detection* yang merupakan model terbaru.

Penelitian [26] menggunakan YOLOv7 menggunakan berbagai *dataset* antara lain: Br35H, Figshare, and SARTAJ *dataset*. *Dataset* yang digabungkan secara total berisikan 7023 gambar berisikan 4 kelas. Selanjutnya, proses pelatihan data menggunakan 300 *epochs*. Penelitian yang dilakukan untuk efisiensi GPU/CPU atau sumber daya pelatihan menggunakan 100 *epochs* saat proses pelatihan. Selanjutnya, *dataset* yang digunakan akan ditambahkan data augmentasi untuk memberikan variasi bentuk *dataset*. Selain itu Model yang digunakan merupakan model terbaru dari YOLOv11.



Gambar 1. Alur penelitian

Penelitian [27] yang telah dilakukan menggunakan *dataset* BR35h yang berisikan 800 citra MRI. Selain itu *epochs* pada proses pelatihan data menggunakan 50 *epochs*. Perbedaan pada penelitian yang dilakukan selain menggunakan versi terbaru *dataset* yang digunakan memiliki *dataset* yang lebih banyak dari penelitian tersebut. Selanjutnya *epochs* yang digunakan pada penelitian yang dilakukan menggunakan 100 *epochs*. Hal tersebut ditujukan untuk meningkatkan performa model terhadap jenis citra yang lebih kaya.

Penelitian [23] yang dilakukan menggunakan *Data Augmentation*. Namun *dataset* pada penelitian tersebut tidak meningkat secara signifikan meskipun telah menggunakan data augmentasi dengan parameter yang sangat banyak. Kelas dan jumlah pada *dataset* yang digunakan pada penelitian adalah Meningioma 708 gambar, Glioma 1426 gambar, Pituitary 920 gambar. Pada penelitian yang dilakukan menggunakan 4 kelas meningioma, glioma, pituitary dan non tumor. Kelas non tumor di tambahkan untuk memberikan variasi dalam *dataset*. Selain itu data augmentasi yang

digunakan berfokus pada penambahan noise disetiap citra yang terdapat pada setiap kelas. Selain itu penelitian [23] tersebut menggunakan *hypermeter batch* 8. Namun pada penelitian yang dilakukan menggunakan *batch* 4 untuk efisiensi penggunaan memori GPU/CPU. Perbedaan terletak pada penggunaan versi YOLOv11, dan kelas yang digunakan saat penelitian yang dilakukan lebih banyak, sedangkan pada penelitian [28] *binary class* yaitu Glioma.

Penelitian [29] menggunakan BRATS 2019 yang berisikan 256 citra MRI. Penelitian ini berhasil mendapatkan akurasi yang sangat tinggi. Namun class yang digunakan adalah *binary class*. Sehingga model tersebut dapat dikatakan tidak dapat beradaptasi terhadap jenis tumor lainnya. Selanjutnya, proses pelatihan menggunakan 10 *epochs* dapat berakibatkan model menjadi *underfitting*. Sehingga model dapat menjadi tidak stabil. Untuk mengatasi *underfitting* penelitian yang dilakukan menggunakan 100 *epochs* saat proses pelatihan. Selain itu, penggunaan *multiple class*.

Penelitian [30] yang dilakukan memberikan hasil akurasi yang sangat tinggi. Meskipun, *epochs* yang digunakan adalah 30 *epochs*. *Hypermeter Optimizer* yang digunakan lainnya adalah *Auto*, *Adamax*, *RMSprop*. Sedangkan pada penelitian yang dilakukan menggunakan *Stochastic Gradient Descent* (SGD) untuk meminimalisirkan terjadi *overfitting* pada model. Pemilihan *optimizer* SGD bertujuan pengoptimalan model tidak hanya pada citra yang terdapat pada *dataset*, namun model dapat mengenali objek diluarnya seperti deteksi objek pada video secara *real-time*.

Penelitian [1] yang dilakukan untuk deteksi tumor menggunakan *Instance* segmentasi, yang pada proses anotasi menggunakan SAM untuk mempersingkat proses anotasi. Penelitian yang dilakukan menggunakan *Bounding Box* yang telah di anotasi oleh pakar yang dibagikan pada platform Kaggle. Selain itu, penggunaan *Bounding Box* yang telah di berikan oleh komunitas dapat menurunkan pembiayaan proses pelatihan maupun prediksi objek. Selanjutnya, untuk menambahkan variasi *dataset* penelitian yang dilakukan menggunakan data augmentasi.

Penelitian [11] menggunakan kumpulan data publik yang berisikan 4 kelas yang secara keseluruhan citra MRI adalah 6930 citra. Mendapatkan kesimpulan meskipun model yang digunakan memiliki kesamaan yaitu penggunaan CNN. YOLOv9 menjadi model dengan performa yang lebih baik dibandingkan dengan algoritma lainnya. Penelitian tersebut juga menyarankan untuk mengintegrasikan model YOLOv9 dengan diagnosa secara *real-time*. Berdasarkan penelitian tersebut, penelitian yang dilakukan yaitu menggunakan YOLOv11 yang merupakan algoritma terbaru dari keluarga YOLO serta mengintegrasikan model dengan *framework* Flask untuk deteksi objek.

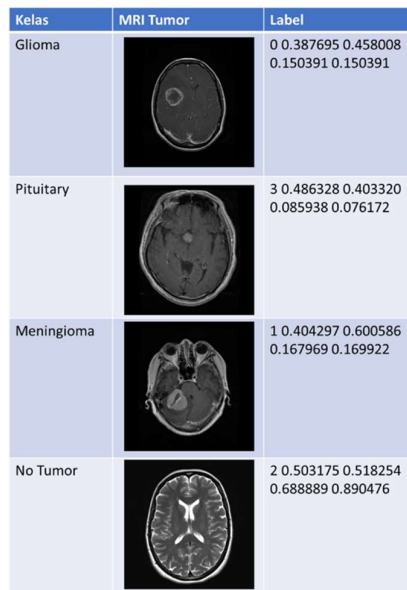
Penelitian [31] menyarankan untuk mengatasi model yang *overfitting* maupun *underfitting* untuk deteksi tumor otak dikarenakan proses pelatihan data yang belum begitu optimal. Untuk mengatasi hal tersebut peneliti menyarankan jumlah kelas maupun jumlah data dalam setiap kelas. Selanjutnya, menggunakan optimasi pada *hypermeter* saat proses pelatihan. Penelitian yang dilakukan mengikuti saran yang telah diberikan antara lain: penggunaan *multiple class*, penggunaan data augmentasi untuk jumlah citra dalam setiap kelas, penggunaan 100 *epochs* untuk *hypermeter* sesuai dengan standar yang disarankan, *optimizer SGD* untuk pengoptimalan model. Penelitian yang dilakukan lebih mempertimbangkan optimasi pada model bukan pada kecepatan proses pelatihan untuk menghindari *underfitting* ataupun *overfitting* pada model.

2.2. Dataset penelitian

Penelitian ini menambahkan Data Augmentasi untuk memperkaya *dataset* yang telah dikumpulkan dari Kaggel [24]. Data augmentasi digunakan agar model lebih mudah mengenali objek di luar *dataset* yang tersedia. Proses *pre-processing dataset* pada penelitian menggunakan platform roboflow. Berikut *dataset* yang digunakan pada penelitian yang dilakukan terlihat pada Tabel 1 dan contoh citra *dataset* pada Gambar 2.

Tabel 1. Jumlah *dataset* pada penelitian

Kelas	Dataset Asli	Augmentasi
Glioma	1382	3292
Meningioma	1117	2645
No Tumor	593	1451
Pituitary	1317	3181



Gambar 2. Contoh *dataset* pada penelitian

Selain Tabel 1 diatas Penelitian yang dilakukan menggunakan *Augmentasi* antara lain: *Flip: Horizontal*

dan *Vertical*, *90° Rotate: Clockwise, Counter-Clockwise, Upside Down*, serta *Noise: Up to 1.5% of pixels*. Selanjutnya, *dataset* yang telah melalui proses augmentasi di bagi menjadi 3 kategori seperti pada Tabel 2 dibawah ini.

Tabel 2. *Splitting dataset*

Data	Persen (%)	Augmentasi
Latih	70	6554
Validasi	20	1873
Testing	10	935
Jumlah	100	9362

2.3. Evaluasi

Penelitian melakukan penilaian kinerja performa model yang telah dilatih menggunakan persamaan antara lain [4]:

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

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


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

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

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5)$$

TP = True Positive, FP = False Positive, FN = False Negative, TN = True Negative.

Selain itu, terdapat parameter lainnya untuk mengevaluasi model berdasarkan hasil grafik *Training* data seperti pada Gambar 3 [4].




Gambar 3. Jenis grafik performa model

2.4. YOLOv11 dan Flask

YOLOv11 merupakan algoritma yang terbaru dalam seri YOLO, dimana memiliki perubahan pada arsitekturnya seperti yang terlihat pada Gambar 4 [32]. C3k2 adalah implementasi yang lebih efisien secara komputasi dari *Cross Stage Partial (CSP) Bottleneck*.

C2PSA merupakan tambahan penting yang meningkatkan perhatian spasial pada peta fitur. Blok C2PSA memungkinkan YOLO11 untuk berkonsentrasi pada area tertentu yang diminati, sehingga berpotensi meningkatkan akurasi deteksi untuk objek dengan berbagai ukuran dan posisi.

Flask adalah *microframework* yang ringan dan tidak memiliki banyak dependensi, sehingga cocok untuk proyek kecil atau menengah yang membutuhkan integrasi ML dengan cepat. Fleksibilitasnya memungkinkan pengembangan untuk menambahkan hanya komponen yang dibutuhkan. Berbeda dengan FastAPI dan Django yang merupakan framework untuk aplikasi dengan skala besar, minimalis *Overhead*, serta tidak fleksibel [33], [34], [35], [36].



Gambar 4. Arsitektur YOLOv11

3. Hasil dan Pembahasan

3.1. Hasil Penelitian

Platform machine learning yang digunakan untuk melatih model adalah Google Colaboratory dengan *library* antara lain: Python 3.11.11, Pytorch 2.5.1 + CUDA 12.1, NVIDIA Tesla T4 dan GPU 15.1 GB. Sedangkan untuk *hypermeter* pada model antara lain: 4 kelas, 4 *batch*, 100 *epochs*, *Optimizer SGD*, *learning rate* 0.01, *momentum* 0.9, ukuran gambar 640 training dan validasi proses, serta menggunakan 2 *worker* atau *thread* untuk membaca dan memuat data secara paralel selama pelatihan data. Pelatihan data yang telah dilakukan mendapatkan seperti pada Tabel 3.

Tabel 3. Hasil pelatihan *dataset*

Class	P	R	mAP	
			50	50-95
All	0.956	0.946	0.977	0.809
Glioma	0.913	0.891	0.957	0.761
Meningioma	0.993	0.986	0.993	0.882
No Tumor	0.998	0.997	0.995	0.86
Pituitary	0.921	0.91	0.963	0.732


Dilain sisi dari penelitian yang dilakukan mendapatkan hasil *F1-Score* seperti pada Tabel 4 menggunakan persamaan (5). *F1-Score* digunakan untuk mengukur model dengan *dataset* yang tidak seimbang seperti

yang telah ditunjukkan pada Tabel 2 terdapat *dataset* yang memiliki jumlah lebih rendah dari kelas lainnya.


Tabel 4. Perhitungan *F1-Score*

Class	P	R	F1-Score
All	0.956	0.946	0.951
Glioma	0.913	0.891	0.902
Meningioma	0.993	0.986	0.989
No Tumor	0.998	0.997	0.997
Pituitary	0.921	0.91	0.915

Selain itu, dalam penelitian mendapatkan hasil *Confusion matrix* yang terlihat pada Gambar 5 dan Gambar 6 merupakan grafik pelatihan model terhadap *dataset*.



Gambar 5. *Confusion matrix* pada pelatihan data

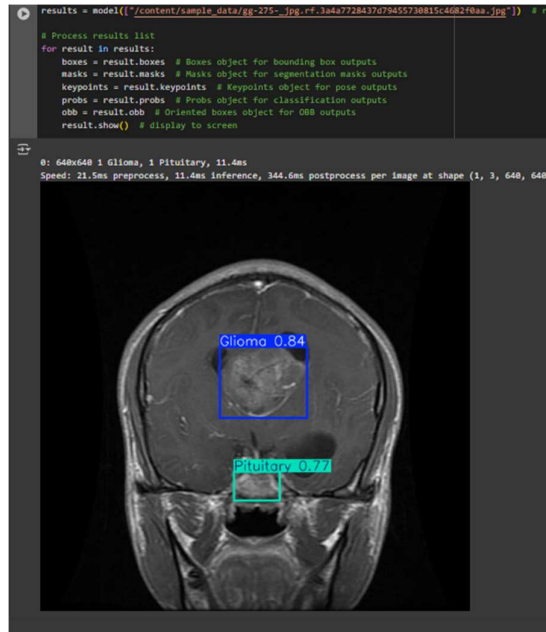


Gambar 6. Grafik pelatihan data

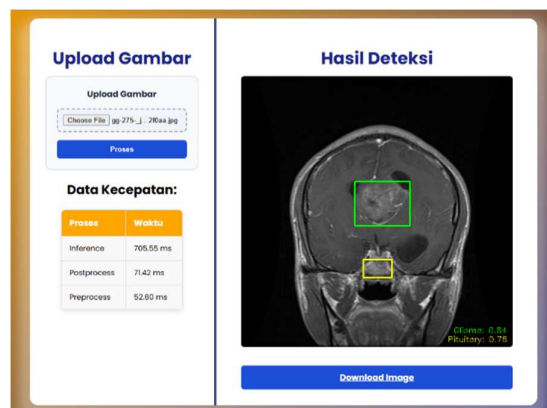
Gambar 5 menunjukkan kinerja model merupakan jenis kinerja model *Good*. Hal tersebut merujuk pada jenis

grafik pelatihan pada Gambar 2 yang telah dipaparkan dibagian sebelumnya.

Selanjutnya, Integrasi model menggunakan Flask sebagai tampilan yang lebih ramah terhadap pengguna, bila dibandingkan pada Gambar 7 yang merupakan tanpa Flask dan Gambar 8 merupakan Gambar deteksi objek menggunakan Flask.



Gambar 7. Tampilan deteksi objek tanpa Flask



Gambar 8. Tampilan deteksi objek Menggunakan Flask

3.2. Pembahasan

Pelatihan model YOLOv11 terhadap *dataset* yang dilakukan penambahan *dataset* menggunakan data augmentasi memberikan solusi terhadap *dataset* yang terbatas pada bidang kesehatan. Penambahan *dataset* yang signifikan seperti yang terlihat pada Tabel 1. Sehingga augmentasi dapat menjadi solusi keterbatasan *dataset* untuk dibidang lainnya.

Meskipun begitu, penggunaan *hypermeter* saat pelatihan data perlu untuk dipertimbangkan antara lain penggunaan *Batch*, *Epochs*, *Optimizer* dan *Learning Rate*. Hal tersebut dilakukan bertujuan untuk model

dapat mempelajari data dengan baik. Tanpa harus melupakan hasil dari evaluasi. Hasilnya pada model terhadap data menunjukkan hasil yang baik disetiap kelasnya seperti yang terlihat pada Tabel 3 dan Tabel 4.

Selanjutnya, berdasarkan Gambar 6 Metrik pelatihan *dataset* menunjukkan bahwa model merupakan jenis grafik model *Goodfit*. Lebih jauh, integrasi antara model yang telah dilatih ke Flask memiliki hasil yang baik seperti pada Gambar 7 yang menunjukkan bahwa model dapat di integrasikan dengan Flask tanpa mengurangi akurasi seperti pada Gambar 7. Gambar 8 merepresentasikan model yang telah terintegrasi dapat mendeteksi 2 kelas tumor Glioma 0.84 dan Pituitary 0.78. Selain itu, penggunaan Flask dapat memberikan kemudahan dalam penggunaan deteksi objek.

4. Kesimpulan

Data Augmentasi yang dilakukan sebagai berikut: *Flip: Horizontal dan Vertical*, *90° Rotate: Clockwise, Counter-Clockwise, Upside Down*, *Noise: Up to 1.5% of pixels*. Data Augmentasi dapat memberikan hasil yang sangat baik saat deteksi objek khusus tumor otak yang terlihat pada hasil *f1-score* untuk semua kelas adalah 0.951. Sehingga keterbatasan *dataset* dapat di tangani menggunakan Data Augmentasi.

Selain itu, pengintegrasian YOLOv11 dan Flask tidak mengalami penurunan akurasi deteksi objek. Namun, memberikan kemudahan dalam penggunaan model untuk deteksi objek tumor otak. Sehingga dapat disimpulkan penggunaan Data Augmentasi dapat dijadikan solusi untuk keterbatasan *dataset* medis serta Flask dapat dijadikan *framework* yang dipertimbangkan untuk pengembangan *Interface Machine Learning*.

Namun, untuk penelitian selanjutnya perlu dilakukan *Batch Upload* gambar untuk deteksi objek. Sehingga dapat mengukur keberhasilan deteksi objek jika gambar yang dimasukkan lebih dari 1. Selain itu, perlu dilakukan penelitian lanjutan untuk tugas lainnya seperti *Instance* segmentasi dengan Flask yang dimana memiliki tingkat kesulitan yang lebih tinggi daripada deteksi objek. Sehingga dapat mengukur kehandalan Flask dalam integrasi model. Selanjutnya, perlu untuk dilakukan penelitian lanjutan terkait integrasi ke database untuk mendukung real-time deteksi objek serta dapat digunakan untuk analisis data.

Ucapan Terimakasih

Terima kasih kepada Universitas Muhammadiyah Klaten yang telah mendanai kegiatan ini. Sehingga dapat terlaksana dengan baik sebagai mana mestinya.

Daftar Rujukan

- [1] A. Ardiansyah, K. N. Qodri, D. Al Banna, and M. Z. Al-Baihaqi, "Pemanfaatan Sam Dan Yolov8 Untuk Deteksi Dan Segmentation Mri Tumor Otak," *TEKNIMEDIA*:

- Teknologi Informasi dan Multimedia*, vol. 5, no. 1, pp. 82–89, Jun. 2024, doi: 10.46764/teknimedia.v5i1.192.
- [2] G. S. Mahendra *et al.*, *Tren Teknologi AI: Pengantar, Teori, dan Contoh Penerapan Artificial Intelligence di Berbagai Bidang*. PT. Sonpedia Publishing Indonesia, 2024.
- [3] A. J. London, “Artificial intelligence in medicine: Overcoming or recapitulating structural challenges to improving patient care?,” *Cell Rep Med*, vol. 3, no. 5, 2022.
- [4] A. Ardiansyah, *Buku Monograf Pengenalan Objek Dalam Bidang Kesehatan*. PT. Sonpedia Publishing Indonesia, 2024.
- [5] B. Z. Wubineh, F. G. Deriba, and M. M. Woldeyohannis, “Exploring the opportunities and challenges of implementing artificial intelligence in healthcare: A systematic literature review,” *Urologic Oncology: Seminars and Original Investigations*, vol. 42, no. 3, pp. 48–56, Mar. 2024, doi: 10.1016/j.urolonc.2023.11.019.
- [6] B. L. Jimma, “Artificial intelligence in healthcare: A bibliometric analysis,” *Telematics and Informatics Reports*, vol. 9, p. 100041, Mar. 2023, doi: 10.1016/j.teler.2023.100041.
- [7] C. Zhu and Y. Guan, “The Risks and Countermeasures of Accounting Artificial Intelligence,” in *Proceedings - 2022 3rd International Conference on Electronic Communication and Artificial Intelligence, IWEC AI 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 358–361. doi: 10.1109/IWEC AI 55315.2022.00076.
- [8] W. Abbaoui, S. Retal, B. El Bhiri, N. Kharmoum, and S. Ziti, “Towards revolutionizing precision healthcare: A systematic literature review of artificial intelligence methods in precision medicine,” *Inform Med Unlocked*, vol. 46, p. 101475, 2024, doi: 10.1016/j.imu.2024.101475.
- [9] N. Xu, D. Yang, K. Arikawa, and C. Bai, “Application of artificial intelligence in modern medicine,” *Clinical eHealth*, vol. 6, pp. 130–137, Dec. 2023, doi: 10.1016/j.ceh.2023.09.001.
- [10] A. Ardiansyah, A. S. Widagdo, K. N. Qodri, S. F. E. Nugroho, and N. A. R. Putri, “Analisis sentimen terhadap pelayanan Kesehatan berdasarkan ulasan Google Maps menggunakan BERT,” *JURNAL FASILKOM*, vol. 13, no. 02, pp. 326–333, Sep. 2023, doi: 10.37859/jf.v13i02.5170.
- [11] A. Alsufyani, “Performance comparison of deep learning models for MRI-based brain tumor detection,” *AIMS Bioeng*, vol. 12, no. 1, pp. 1–21, 2025, doi: 10.3934/bioeng.2025001.
- [12] A. Ahmed, R. Xi, M. Hou, S. A. Shah, and S. Hameed, “Harnessing Big Data Analytics for Healthcare: A Comprehensive Review of Frameworks, Implications, Applications, and Impacts,” *IEEE Access*, vol. 11, pp. 112891–112928, 2023, doi: 10.1109/ACCESS.2023.3323574.
- [13] A. M. Filho *et al.*, “Cancers of the brain and central nervous system: global patterns and trends in incidence,” *J Neurooncol*, Jan. 2025, doi: 10.1007/s11060-025-04944-y.
- [14] V. Kaul, S. Enslin, and S. A. Gross, “History of artificial intelligence in medicine,” *Gastrointest Endosc*, vol. 92, no. 4, pp. 807–812, Oct. 2020, doi: 10.1016/j.gie.2020.06.040.
- [15] 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,” *arXiv preprint arXiv:2207.02696*, 2022.
- [16] W. Wei *et al.*, “YOLOv11-based multi-task learning for enhanced bone fracture detection and classification in X-ray images,” *J Radiat Res Appl Sci*, vol. 18, no. 1, p. 101309, Mar. 2025, doi: 10.1016/j.jrras.2025.101309.
- [17] 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.
- [18] N. Nyi Myo, A. Boonkong, K. Khampitak, and D. Hormdee, “A Two-Point Association Tracking System Incorporated With YOLOv11 for Real-Time Visual Tracking of Laparoscopic Surgical Instruments,” *IEEE Access*, vol. 13, pp. 12225–12238, 2025, doi: 10.1109/ACCESS.2025.3529710.
- [19] A. Anish, S. R. A. H. Malini, and T. Archana, “Enhancing Surveillance Systems with YOLO Algorithm for Real-Time Object Detection and Tracking,” in *2023 2nd International Conference on Automation, Computing and Renewable Systems (ICACRS)*, IEEE, Dec. 2023, pp. 1254–1257. doi: 10.1109/ICACRS58579.2023.10404710.
- [20] G. S. Patel, A. A. Desai, Y. Y. Kamble, G. V. Pujari, P. A. Chougule, and V. A. Jujare, “Identification and Separation of Medicine Through Robot Using YOLO and CNN Algorithms for Healthcare,” in *2023 International Conference on Artificial Intelligence for Innovations in Healthcare Industries (ICAIHI)*, IEEE, Dec. 2023, pp. 1–5. doi: 10.1109/ICAIHI57871.2023.10489407.
- [21] S. Pandey, K.-F. Chen, and E. B. Dam, “Comprehensive Multimodal Segmentation in Medical Imaging: Combining YOLOv8 with SAM and HQ-SAM Models,” in *2023 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, IEEE, Oct. 2023, pp. 2584–2590. doi: 10.1109/ICCVW60793.2023.00273.
- [22] Rachmat Santoso, “Augmentasi Data pada Prastasi Logam untuk Deteksi Aksara Kawi,” *JURNAL FASILKOM*, vol. 14, no. 1, pp. 234–241, Apr. 2024, doi: 10.37859/jf.v14i1.6952.
- [23] 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.
- [24] A. Sorour1, “MRI Images for Brain Tumors For Object Detection or Classification,” Kaggle. Accessed: Jan. 25, 2025. [Online]. Available: <https://www.kaggle.com/datasets/ahmedsorour1/mri-for-brain-tumor-with-bounding-boxes/data>
- [25] 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.
- [26] B. S. S and N. B. Muppalaneni, “Automated Multimodal Brain Tumor Classification Using a YOLOv7 Approach,” in *2023 9th International Conference on Control, Decision and Information Technologies (CoDIT)*, IEEE, Jul. 2023, pp. 35–40. doi: 10.1109/CoDIT58514.2023.10284388.
- [27] 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.
- [28] 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.
- [29] S. Sankara Narayanan, L. C. Meena, K. C. Thanu, and P. Chandrasekar, “Enhancing Glioma Brain Tumor Detection from MRI using Deep Learning Techniques,” in *2023 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI)*, IEEE, Dec. 2023, pp. 1–6. doi: 10.1109/ICDSAAI59313.2023.10452496.
- [30] C. Mahale, S. Meshram, and A. Pakhmode, “Brain Tumor Detection with YOLOv8,” in *2023 4th International Conference on Intelligent Technologies (CONIT)*, IEEE, Jun. 2024, pp. 1–5. doi: 10.1109/CONIT61985.2024.10626992.
- [31] R. Zaitoon and H. Syed, “A Comprehensive Review: Tumour Recognition, Segmentation and Classification in Brain MRI,” in *2024 International Conference on Expert Clouds and Applications (ICOECA)*, IEEE, Apr. 2024, pp. 865–870. doi: 10.1109/ICOECA62351.2024.00152.
- [32] R. Khanam and M. Hussain, “YOLOv11: An Overview of the Key Architectural Enhancements,” Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [33] K. Mahesh, P. Aishwarya, S. Nithin, S. Hariharan, B. Vaishnavi, and V. S V, “Predictive Cardiovascular Health Assessment with Flask and Machine Learning Models,” in *2025 International Conference on Intelligent Control, Computing and Communications (IC3)*, IEEE, Feb. 2025, pp. 222–226. doi: 10.1109/IC363308.2025.10956662.
- [34] S. Aswathi and G. Nagappan, “A Deep Learning Driven Flask Level Enhanced Web Application for Efficient

-
- [35] Communication System,” in *2024 IEEE International Conference on Computing, Power and Communication Technologies (IC2PCT)*, IEEE, Feb. 2024, pp. 1207–1210. doi: 10.1109/IC2PCT60090.2024.10486554.
- [36] P. Kuntekar, N. Bhavsar, K. Das, and S. Bhavsar, “Use of Docker Containerization and Load Balancer to Scale a Flask Application,” in *2024 4th International Conference on Soft Computing for Security Applications (ICSCSA)*, IEEE, Sep. 2024, pp. 534–541. doi: 10.1109/ICSCSA64454.2024.00092.
- [36] B. C. Krishna, P. J. Angelina, S. J. Malla, B. Naseeba, and B. Althaph, “Real-Time Object Detection Using Yolov9c and Flask Web Application,” in *2024 3rd Edition of IEEE Delhi Section Flagship Conference (DELCON)*, IEEE, Nov. 2024, pp. 1–4. doi: 10.1109/DELCON64804.2024.10866465.