

Pengembangan Model Deteksi Tumor Otak pada Magnetic Resonance Imaging Menggunakan Arsitektur YOLOv10

Brain Tumor Detection on Magnetic Resonance Imaging Using the YOLOv10 Architecture Model Development

Akbar Ihsanul Ahadin^{1*}, Fida Maisa Hana², Agung Prihandono³
^{1,2,3}Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Kudus

*corr_author: 32021110004@std.umku.ac.id

ABSTRAK

Dengan meningkatnya kebutuhan akan diagnosis yang cepat dan akurat dalam bidang medis, model deteksi berbasis deep learning menawarkan solusi yang menjanjikan. Penelitian ini bertujuan untuk mengembangkan model deteksi tumor otak pada citra *Magnetic Resonance Imaging* (MRI) menggunakan arsitektur YOLOv10. YOLOv10 dipilih karena kemampuannya dalam melakukan deteksi objek secara real-time dengan tingkat akurasi yang tinggi. Dalam penelitian ini, dataset MRI otak yang terdiri dari 1003 gambar digunakan untuk melatih model. Proses pelatihan dilakukan dengan menggunakan berbagai jumlah epoch untuk mengidentifikasi parameter yang optimal. Hasil menunjukkan bahwa model YOLOv10 mampu mendeteksi tumor otak dengan tingkat presisi yang tinggi, dengan metrics precision sebesar 97,88%, recall 95,24%, dan mAP50 sebesar 95,84% pada epoch 200. Model ini diharapkan dapat digunakan sebagai alat bantu bagi para profesional medis dalam mendeteksi tumor otak secara lebih efisien dan efektif, serta memberikan kontribusi signifikan dalam bidang diagnosa penyakit menggunakan teknologi berbasis kecerdasan buatan.

Kata-kata kunci: *deep learning, tumor otak, You Only Look Once*

ABSTRACT

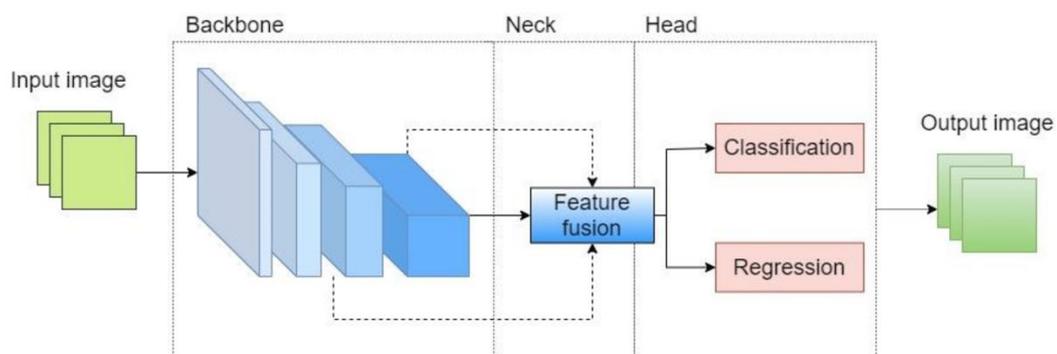
With the increasing need for fast and accurate diagnosis in the medical field, deep learning-based detection models offer a promising solution. This study aims to develop a brain tumor detection model on Magnetic Resonance Imaging (MRI) using the YOLOv10 architecture. YOLOv10 was chosen for its ability to perform real-time object detection with high accuracy. In this study, a brain MRI dataset consisting of 1,003 images was used to train the model. The training process was conducted using various numbers of epochs to identify the optimal parameters. The results showed that the YOLOv10 model could detect brain tumors with high precision, achieving metrics of 97.88% precision, 95.24% recall, and 95.84% mAP50 at 200 epochs. This model is expected to serve as an aid for medical professionals in detecting brain tumors more efficiently and effectively, and to make a significant contribution to the field of disease diagnosis using artificial intelligence-based technology.

Keywords: *brain tumor, deep learning, You Only Look Once*

PENDAHULUAN

Pada tahun 2020, diperkirakan ada 308.102 orang yang didiagnosis dengan tumor otak di seluruh dunia (Sung *et al.*, 2021). Tumor otak merupakan salah satu penyakit yang memiliki tingkat morbiditas dan mortalitas tinggi di seluruh dunia dan tumor otak merupakan penyebab kematian ke-10 di dunia (Toufiq *et al.*, 2021). Oleh karena itu, deteksi dan identifikasi tumor otak pada tahap awal sangat penting untuk keberhasilan pengobatan. Hal ini berperan sangat penting dalam meningkatkan pengobatan dan memastikan kemungkinan bertahan hidup yang lebih tinggi. Deteksi dini dan diagnosis yang akurat sangat penting untuk meningkatkan peluang kesembuhan pasien. Ada beberapa teknik pencitraan medis dan metode diagnostik yang digunakan untuk memperoleh informasi tentang tumor, seperti pemindaian *Computed Tomography* (CT) dan *Magnetic Resonance Imaging* (MRI) yang dapat membedakan antara sel normal dan abnormal yang tumbuh di otak. *Magnetic Resonance Imaging* (MRI) adalah salah satu modalitas pencitraan yang paling efektif dan sering digunakan untuk mendeteksi abnormalitas pada otak, termasuk tumor (Ahmad and Choudhury, 2022). Namun, interpretasi manual citra MRI oleh radiolog memerlukan waktu yang cukup lama dan bergantung pada pengalaman individu, yang dapat menyebabkan variasi dalam akurasi diagnosis. Oleh karena itu, pengembangan sistem deteksi otomatis berbasis deep learning dapat memberikan solusi yang signifikan (Asad *et al.*, 2023).

Seiring dengan kemajuan teknologi *deep learning*, model-model berbasis *convolutional neural network* (CNN) telah menunjukkan kemampuan luar biasa dalam deteksi dan klasifikasi objek pada berbagai domain, termasuk medis (Musallam *et al.*, 2022). Salah satu arsitektur yang populer dan efisien dalam mendeteksi objek, terutama secara *real-time* adalah *You Only Look Once* (YOLO) (Gambar 1). YOLOv10, sebagai pengembangan terbaru dari YOLO, dirancang untuk memberikan keseimbangan antara kecepatan dan akurasi dalam deteksi objek, menjadikannya pilihan ideal untuk aplikasi di bidang medis, seperti deteksi tumor otak pada citra MRI. Deteksi tumor otak menggunakan pencitraan medis telah menjadi fokus penelitian selama beberapa dekade terakhir. *Magnetic Resonance Imaging* (MRI) merupakan salah satu modalitas pencitraan yang paling efektif dalam mendeteksi abnormalitas pada otak, termasuk tumor. Berbeda dengan teknik pencitraan lainnya seperti CT scan, MRI tidak menggunakan radiasi ion, sehingga dianggap lebih aman untuk diagnosis jangka panjang. Analisis citra MRI secara manual oleh tenaga medis sering kali memakan waktu dan rentan terhadap kesalahan subjektif, yang membuat pengembangan sistem otomatis berbasis *Artificial intelligence* (AI) menjadi sangat diperlukan (Aleid *et al.*, 2023).



Gambar 1. Arsitektur *You Only Look Once*

Beberapa penelitian sebelumnya yang telah dilakukan untuk mengklasifikasikan tumor otak misalnya penelitian yang dilakukan pada tahun 2022 yang menggunakan data citra sebesar 421 dengan pembagian data 213 untuk klasifikasi berdasarkan ukuran tumor otak dan 208 data citra berdasarkan tipe tumor otak yang menghasilkan akurasi 76% menggunakan metode ekstraksi fitur GLCM dan algoritma klasifikasi *Support Vector Machine* (Tika and Qudsiyah, 2022). Pada penelitian dengan ekstraksi fitur menggunakan metode *Data Wavelet Transform* dan metode *Adaptive Neighborhood Neural Network* yang menghasilkan akurasi 87,5% dengan jumlah data yang dieksekusi sebanyak 32 yang terdiri atas 8 citra normal dan 24 citra abnormal (Astuti, 2019). Penelitian tahun 2019 yang menggunakan 3064 gambar T1 dengan kontras yang ditingkatkan sebagai dataset yang diperoleh dari 233 pasien yang terdiri atas tiga jenis tumor otak yakni Glioma (1426), Meningioma (708), dan Pituitary (930) yang menghasilkan akurasi validasi sebesar 88,72% dan 85,56% menggunakan metode RF-PCA (Saraswathi and Gupta, 2019). Penelitian selanjutnya yang dilakukan untuk proses klasifikasi citra tumor otak menggunakan algoritma metode *Naïve Bayes* yang menghasilkan akurasi sebesar 84,17% yang didapatkan dari 39 data citra yang terdiri atas 19 data abnormal dan 20 data normal (Akbar *et al.*, 2019).

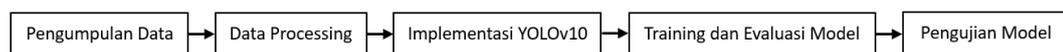
You Only Look Once (YOLO) merupakan algoritma *deep learning* yang dirancang untuk deteksi objek menggunakan jaringan saraf cerdas, dan juga merupakan salah satu model *deep learning* yang dirancang untuk deteksi objek secara real-time. YOLO dikenal karena kemampuannya yang efisien dalam mendeteksi objek pada citra dengan kecepatan tinggi, tanpa mengorbankan akurasi. YOLO bekerja dengan menggunakan jaringan saraf tunggal yang memproses seluruh gambar secara langsung, membaginya menjadi beberapa area, dan memprediksi kotak batas serta probabilitas kehadiran objek. Setiap kotak batas dinilai untuk kemungkinan mengandung objek tertentu, dan klasifikasi dilakukan untuk menentukan apakah kotak tersebut berisi objek atau bukan (Mulyana and Rowis, 2022). Arsitektur deteksi YOLO terdiri dari beberapa lapisan, termasuk 24 lapisan konvolusi yang berfungsi sebagai lapisan konvolusional dan lapisan terhubung penuh yang memproses fitur-fitur gambar. Struktur dasar YOLO melibatkan empat komponen utama seperti yang terlihat pada Gambar 1, yaitu *input*, *backbone*, *neck*, dan *head layer*, yang berperan dalam alur deteksi objek. Proses dimulai dari lapisan masukan yang mengelola gambar dan meneruskannya ke lapisan *backbone* untuk ekstraksi fitur. *Neck layer* membantu dalam penggabungan fitur multi-skala yang kemudian diteruskan ke *head layer* untuk melakukan prediksi objek melalui kotak batas dan probabilitas. Pendekatan YOLO memungkinkan deteksi objek yang lebih efisien dan cepat dibandingkan metode deteksi objek konvensional lainnya.

Penelitian ini bertujuan untuk mengembangkan model deteksi tumor otak menggunakan arsitektur YOLOv10 pada citra MRI. YOLOv10 sebagai pengembangan terbaru, menawarkan peningkatan dalam arsitektur dengan fokus pada pengurangan kompleksitas model serta mempertahankan kinerja deteksi yang unggul. YOLOv10 memiliki kemampuan yang lebih baik dalam menangani deteksi objek pada berbagai skala, yang sangat relevan untuk aplikasi dalam citra medis. Dengan menggunakan dataset yang terdiri dari 1003 gambar MRI, model ini dilatih untuk mendeteksi keberadaan tumor otak secara otomatis. Penggunaan YOLOv10 diharapkan dapat mengurangi waktu deteksi dan meningkatkan konsistensi dalam diagnosis, sehingga mendukung tenaga medis dalam pengambilan keputusan klinis yang lebih cepat dan akurat. Meskipun terdapat beberapa penelitian sebelumnya yang telah menggunakan teknik *deep learning* untuk deteksi tumor otak, penelitian ini menawarkan pendekatan baru dengan memanfaatkan YOLOv10, yang memiliki keunggulan dalam hal kecepatan dan efisiensi komputasi. Hal ini penting, mengingat deteksi *real-time* dapat memberikan manfaat langsung dalam situasi klinis di

mana keputusan harus diambil dengan cepat. Selain itu, penggunaan YOLOv10 yang lebih ringan dibandingkan dengan model lain memungkinkan penerapan pada perangkat keras dengan spesifikasi yang lebih rendah, tanpa mengorbankan akurasi. Dalam penelitian ini, berbagai parameter dan konfigurasi model YOLOv10 dieksplorasi untuk menemukan setelan yang paling optimal dalam mendeteksi tumor otak pada gambar MRI. Penggunaan arsitektur YOLO dalam deteksi tumor otak masih relatif jarang diteliti, memberikan ruang yang besar untuk inovasi dalam bidang ini. Dalam penelitian ini, arsitektur YOLOv10 digunakan untuk mendeteksi tumor otak pada citra MRI, pendekatan ini diharapkan mampu memberikan hasil yang lebih cepat dan akurat dibandingkan metode-metode konvensional.

METODE PENELITIAN

Alur penelitian dapat dilihat pada Gambar 2, yang dimulai dari tahap pengumpulan data yang mencakup elemen-elemen penting yang diperlukan untuk mencapai tujuan penelitian. Kemudian, dilakukan preprocessing dan labeling pada data untuk meningkatkan kualitas data dan mempersiapkan data untuk pelatihan model. Tahap berikutnya adalah implementasi YOLOv10, di mana algoritma deteksi objek ini diterapkan untuk mendeteksi tumor otak. Dengan memanfaatkan fitur-fitur unggul dari YOLOv10, kemampuan pendeteksian objek dapat dioptimalkan. Data yang telah diberi label digunakan sebagai dasar pelatihan model. Proses pelatihan melibatkan penyajian data berlabel kepada model agar model dapat mempelajari pola dan meningkatkan kemampuan mengenali serta mengklasifikasikan objek secara akurat. Setelah pelatihan, model dievaluasi secara komprehensif untuk menilai kinerjanya menggunakan berbagai metrik dan indikator kinerja, evaluasi ini bertujuan untuk mengukur efektivitas model dalam memenuhi tujuan penelitian. Selanjutnya, pengujian model deteksi dilakukan dengan menggunakan berbagai skenario untuk memvalidasi penerapan model di dunia nyata, menguji ketahanan dan keandalan model dalam berbagai kondisi lingkungan, dan penelitian diakhiri dengan tahap analisis dan kesimpulan yang merangkum temuan dari seluruh proses penelitian.



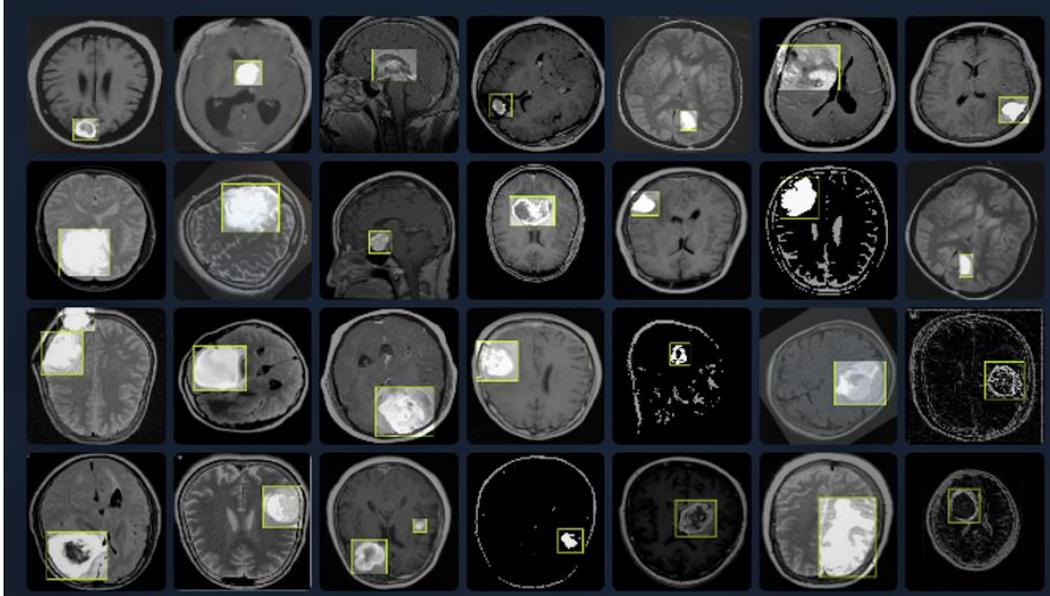
Gambar 2. Arsitektur You Only Look Once

1. Dataset

Penelitian ini menggunakan data MRI otak dengan dataset yang digunakan terdiri dari 1.003 gambar MRI yang telah dibagi menjadi tiga kelompok, yaitu 697 gambar (69%) untuk pelatihan, 197 gambar (20%) untuk validasi, dan 109 gambar (11%) untuk pengujian. Dataset MRI yang digunakan adalah dataset yang disediakan oleh Roboflow (MRI, 2023). Dataset gambar MRI otak dapat dilihat pada Gambar 3. Perlu diperhatikan bahwa gambar medis memiliki kompleksitas yang lebih tinggi dibandingkan dengan gambar alami, sehingga membutuhkan analisis dan interpretasi dengan tingkat keahlian yang lebih tinggi.

Pemisahan dataset dilakukan berdasarkan set pelatihan, validasi, dan pengujian untuk memastikan evaluasi model yang objektif. Set pelatihan digunakan untuk mengajarkan model mengenali pola-pola dalam gambar MRI. Set validasi digunakan untuk membantu dalam mengukur kinerja model selama pelatihan dan menghindari *overfitting*. Set pengujian digunakan untuk menilai kemampuan model dalam mendeteksi tumor pada gambar yang belum pernah dilihat sebelumnya, yang memungkinkan pengukuran kemampuan generalisasi model. Pembagian dataset ini dilakukan secara acak untuk menghindari adanya bias seleksi yang dapat mempengaruhi hasil evaluasi. Dengan cara ini, model dapat diuji efektivitasnya secara objektif terhadap data baru, memastikan bahwa performa deteksi tumor otak tidak hanya terbatas pada data yang telah digunakan dalam

proses pelatihan. Penggunaan jumlah data pelatihan yang lebih besar berkontribusi pada pengembangan model yang lebih andal dan akurat dalam deteksi tumor otak pada MRI.



Gambar 3. Dataset MRI tumor otak

2. Data Preprocessing

Prapemrosesan data merupakan tahap penting yang melibatkan pembersihan, pengorganisasian, dan penyesuaian data agar lebih optimal untuk digunakan dalam proses pelatihan model. Dalam penelitian ini, prapemrosesan dilakukan karena terdapat beberapa citra dengan posisi objek yang tidak ideal, seperti objek yang terpotong, terlalu kecil, atau terdistorsi oleh latar belakang yang kompleks. Prapemrosesan gambar dilakukan untuk memformat gambar guna memastikan kualitas dan keseragaman gambar sebelum dimasukkan ke dalam model.

Proses ini memainkan peran penting dalam prosedur selanjutnya karena dapat mengurangi waktu pelatihan model dan meningkatkan akurasi deteksi secara keseluruhan (Maharana *et al.*, 2022). Banyak arsitektur model, termasuk yang digunakan dalam penelitian ini, memiliki ukuran input tertentu, arsitektur YOLOv10 hanya menerima gambar dengan ukuran 640 x 640 piksel. Meskipun resizing dapat menyebabkan hilangnya informasi tertentu, proses ini tetap penting untuk memastikan gambar konsisten dan sesuai dengan spesifikasi model.

Hal ini bertujuan untuk menjaga keseimbangan antara akurasi deteksi dan efisiensi komputasi selama pelatihan, meskipun perubahan ukuran yang berlebihan sering kali membuat gambar kehilangan informasi tertentu dalam prosesnya (Anushkannan *et al.*, 2022). Meskipun ukuran gambar yang lebih besar dapat menghasilkan hasil yang lebih baik, hal ini juga dapat memakan waktu lebih lama untuk melatih model karena mengandung banyak informasi. Oleh karena itu, penting untuk memastikan gambar input diubah dengan hati-hati tanpa mempengaruhi kualitas gambar.

Gambar MRI tumor otak menjalani beberapa tahap prapemrosesan untuk standarisasi dan menyiapkannya untuk klasifikasi. Pertama, gambar berwarna RGB dikonversi menjadi skala abu-abu untuk menyederhanakan data dan mengurangi beban komputasi. Selanjutnya, gambar diubah ukurannya menjadi resolusi 640 x 640 piksel untuk memastikan konsistensi ukuran di seluruh dataset. Pengurangan noise juga dilakukan untuk melembutkan gambar namun tetap mempertahankan detail penting. Untuk menajamkan gambar dan mengekstraksi fitur penting, digunakan filter *high-pass* yang membantu

memperjelas tepi dan detail halus. Selain itu, kontur gambar diidentifikasi dan diproses untuk menghapus area hitam yang tidak diinginkan, sehingga gambar akhir lebih siap untuk diolah oleh model jaringan saraf.

Kualitas, kuantitas, dan relevansi data pelatihan sangat memengaruhi keberhasilan model. Kekurangan data sering menjadi kendala dalam penerapan machine learning. Untuk mengatasi ini, augmentasi data seperti rotasi, penskalaan, penambahan noise, dan perubahan kecerahan digunakan untuk meningkatkan ukuran dan keragaman dataset (Zoph *et al.*, 2020). Misalnya, gambar dapat diperbesar dengan zoom in, dibalik secara horizontal atau vertikal, dan kecerahan diubah sesuai kebutuhan. Teknik augmentasi ini tidak hanya memperkaya dataset tetapi juga membantu mengurangi overfitting, sehingga model lebih mampu melakukan generalisasi terhadap data baru.

3. Implementasi YOLOv10

YOLOv10 adalah versi terbaru dari algoritma YOLO yang dirilis oleh Ultralytics pada tahun 2024. YOLOv10, dibangun pada paket Ultralytics Python oleh para peneliti di Universitas Tsinghua, memperkenalkan pendekatan baru untuk deteksi objek *real-time*, mengatasi kekurangan pasca-pemrosesan dan arsitektur model yang ditemukan pada versi YOLO sebelumnya. Dengan menghilangkan penekanan non-maksimum (NMS) dan mengoptimalkan berbagai komponen model, YOLOv10 mencapai kinerja tercanggih dengan pengurangan *overhead* komputasi secara signifikan. Eksperimen ekstensif menunjukkan *trade-off* akurasi-latensi yang unggul di berbagai skala model (Wang *et al.*, 2024). Dibandingkan dengan model sebelumnya dalam seri YOLO, YOLOv10 menawarkan peningkatan signifikan dalam hal akurasi dan kecepatan deteksi objek. Struktur arsitektur YOLOv10 terdiri dari beberapa elemen utama yang berfungsi untuk mengolah masukan gambar dan menghasilkan prediksi yang lebih akurat dan efisien.

Dalam YOLOv10, jaringan masukan mencakup beberapa fitur inovatif seperti peningkatan data mosaik, pengubahan ukuran gambar otomatis, dan perhitungan kotak jangkar adaptif. Peningkatan data mozaik adalah teknik yang diperkenalkan di versi YOLO sebelumnya yang memperkaya latar belakang dan objek kecil dengan menggabungkan empat gambar pelatihan untuk meningkatkan deteksi objek kecil. Perhitungan kotak jangkar adaptif pada YOLOv10 dilakukan dengan membandingkan kotak prediksi yang dihasilkan model dengan kotak kebenaran dasar (ground truth) menggunakan kotak jangkar awal. Kesenjangan antara keduanya dihitung dan diperbarui secara berulang melalui proses pembelajaran terbalik hingga didapatkan parameter kotak jangkar yang paling sesuai. Dengan inovasi-inovasi ini, YOLOv10 menunjukkan peningkatan performa yang signifikan, baik dalam hal deteksi objek dengan akurasi tinggi maupun efisiensi waktu dalam proses inferensi, membuatnya menjadi pilihan yang canggih untuk aplikasi deteksi objek masa kini.

Model ini menggunakan penetapan label ganda selama pelatihan, *one-to-many* untuk pengawasan yang kompleks dan *one-to-one* untuk inferensi yang efisien. Pendekatan ini menyelaraskan pengawasan, sehingga menghasilkan kinerja yang lebih baik tanpa tambahan biaya inferensi. Lapisan arsitektur YOLOv10 bisa dilihat pada Gambar 4.

	from	n	params	module	arguments
0	-1	1	464	ultralytics.nn.modules.conv.Conv	[3, 16, 3, 2]
1	-1	1	4672	ultralytics.nn.modules.conv.Conv	[16, 32, 3, 2]
2	-1	1	7360	ultralytics.nn.modules.block.C2f	[32, 32, 1, True]
3	-1	1	18560	ultralytics.nn.modules.conv.Conv	[32, 64, 3, 2]
4	-1	2	49664	ultralytics.nn.modules.block.C2f	[64, 64, 2, True]
5	-1	1	9856	ultralytics.nn.modules.block.SCDOWN	[64, 128, 3, 2]
6	-1	2	197632	ultralytics.nn.modules.block.C2f	[128, 128, 2, True]
7	-1	1	36096	ultralytics.nn.modules.block.SCDOWN	[128, 256, 3, 2]
8	-1	1	460288	ultralytics.nn.modules.block.C2f	[256, 256, 1, True]
9	-1	1	164608	ultralytics.nn.modules.block.SPPF	[256, 256, 5]
10	-1	1	249728	ultralytics.nn.modules.block.PSA	[256, 256]
11	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
12	[-1, 6]	1	0	ultralytics.nn.modules.conv.Concat	[1]
13	-1	1	148224	ultralytics.nn.modules.block.C2f	[384, 128, 1]
14	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
15	[-1, 4]	1	0	ultralytics.nn.modules.conv.Concat	[1]
16	-1	1	37248	ultralytics.nn.modules.block.C2f	[192, 64, 1]
17	-1	1	36992	ultralytics.nn.modules.conv.Conv	[64, 64, 3, 2]
18	[-1, 13]	1	0	ultralytics.nn.modules.conv.Concat	[1]
19	-1	1	123648	ultralytics.nn.modules.block.C2f	[192, 128, 1]
20	-1	1	18048	ultralytics.nn.modules.block.SCDOWN	[128, 128, 3, 2]
21	[-1, 10]	1	0	ultralytics.nn.modules.conv.Concat	[1]
22	-1	1	282624	ultralytics.nn.modules.block.C2fCIB	[384, 256, 1, True, True]
23	[16, 19, 22]	1	862108	ultralytics.nn.modules.head.v10Detect	[2, [64, 128, 256]]

YOLOv10n summary: 385 layers, 2707820 parameters, 2707804 gradients, 8.4 GFLOPS

Gambar 4. Lapisan konvolusi YOLOv10

Berdasarkan Gambar 4 terlihat sebuah arsitektur model *You Only Look Once* versi 10 yang digunakan dalam penelitian ini memiliki arsitektur yang memiliki struktur jaringan yang kompleks dengan total 385 lapisan, terdiri dari 27.078.720 parameter dan 27.078.704 gradien, serta 8.4 GFLOPS untuk komputasi. Model ini dirancang untuk mencapai performa deteksi objek yang tinggi dengan memadukan beberapa modul arsitektur modern. Pada bagian awal, model menggunakan beberapa lapisan konvolusi (Conv) dengan kernel 3x3 dan stride 2 untuk downsampling dan ekstraksi fitur awal. Kemudian, blok-blok C2f (Cross Stage Partial connections) yang dioptimalkan untuk efisiensi parameter diimplementasikan, di mana modul ini memfasilitasi aliran informasi lebih baik dengan penggunaan koneksi parsial yang mengurangi redundansi parameter. Struktur arsitektur YOLOv10 ini juga mencakup modul SCDOWN (Spatial Convolution Downsampling) untuk melakukan downsampling yang lebih efisien, menjaga informasi spasial yang penting dalam gambar MRI. SPPF (Spatial Pyramid Pooling Fast) digunakan untuk mengekstraksi fitur dari berbagai skala, memperkuat kemampuan deteksi model terhadap objek dengan ukuran dan bentuk yang bervariasi. Selain itu, PSA (Position-Sensitive Attention) membantu meningkatkan fokus pada area kritis dalam gambar, yang relevan untuk mendeteksi tumor otak.

Arsitektur ini menggabungkan berbagai lapisan upsampling dan concatenation untuk mengintegrasikan informasi dari berbagai resolusi, yang bertujuan untuk meningkatkan akurasi deteksi pada fitur skala kecil hingga besar. Modul terakhir, yaitu v10Detect, bertanggung jawab untuk melakukan deteksi akhir terhadap objek dengan menggunakan tiga skala deteksi yang berbeda, memastikan bahwa model dapat mendeteksi objek dengan ukuran beragam secara efektif. Secara keseluruhan, kombinasi modular ini memungkinkan YOLOv10 untuk menangani tugas deteksi tumor pada gambar MRI dengan efisiensi dan akurasi tinggi, berkat penggunaan teknik inovatif yang mengoptimalkan penggunaan parameter dan sumber daya komputasi.

HASIL DAN PEMBAHASAN

1. Metriks Evaluasi

Untuk memvalidasi kinerja dari pendekatan yang diusulkan, digunakan indikator pengukuran seperti precision, recall, dan mean average precision (mAP) (Padilla *et al.*, 2020). Precision adalah rasio dari sampel positif yang diklasifikasikan dengan benar terhadap total jumlah sampel yang diklasifikasikan sebagai positif, sedangkan recall adalah rasio dari sampel positif yang diklasifikasikan dengan benar terhadap semua sampel positif. Precision dan recall didefinisikan dalam (1) dan (2).

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

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

di mana TP adalah jumlah objek yang terdeteksi dengan benar, FP adalah jumlah objek yang terdeteksi secara salah, FN adalah jumlah objek yang tidak terdeteksi oleh model, dan TN adalah jumlah objek yang dengan benar tidak terdeteksi. Mean average precision adalah rata-rata dari semua average precision. YOLO menghitung dua jenis mAP, yaitu mAP50 dan mAP50-95 yang didefinisikan dalam (3) dan (4).

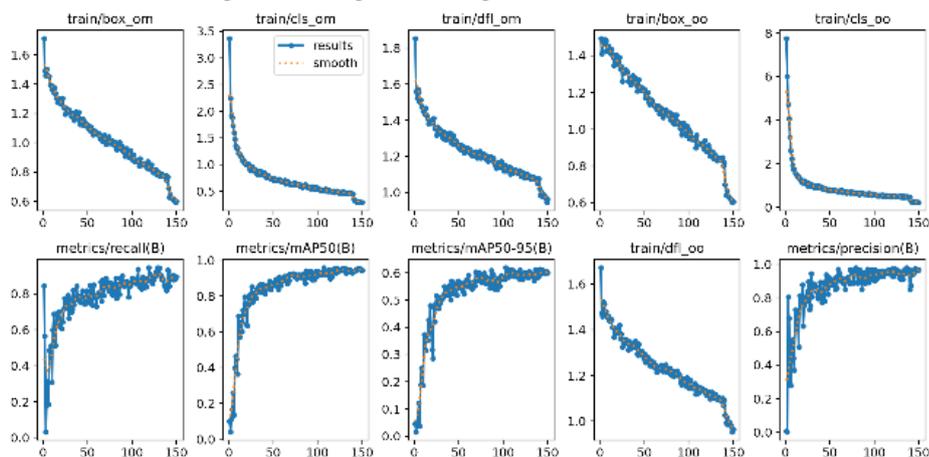
$$Average\ Precision\ (AP) = \int_0^1 P(R)d(R) \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

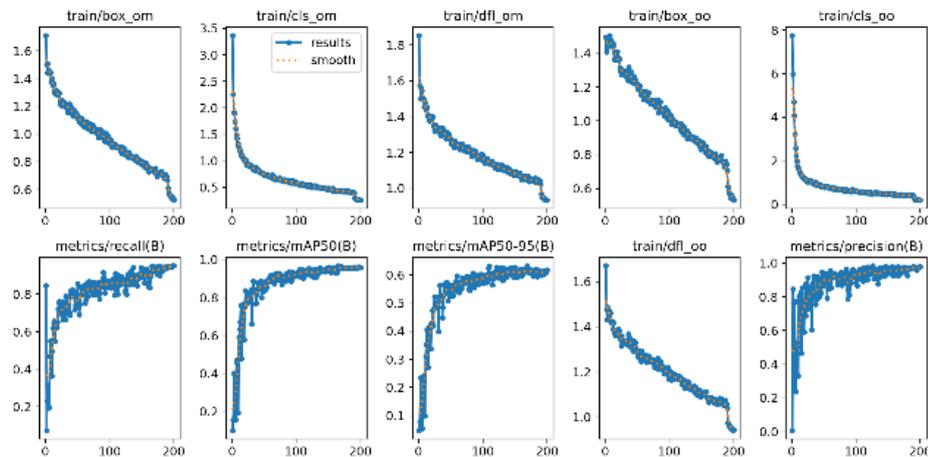
di mana P(R) adalah nilai precision pada recall tertentu, d(R) adalah perbedaan antara recall saat ini dan recall berikutnya, sedangkan N adalah jumlah total kelas dalam dataset. mAP50 menghitung rata-rata dari average precision (AP) dari semua kelas ketika ambang IoU adalah 0,5.

2. Training dan Evaluasi Model

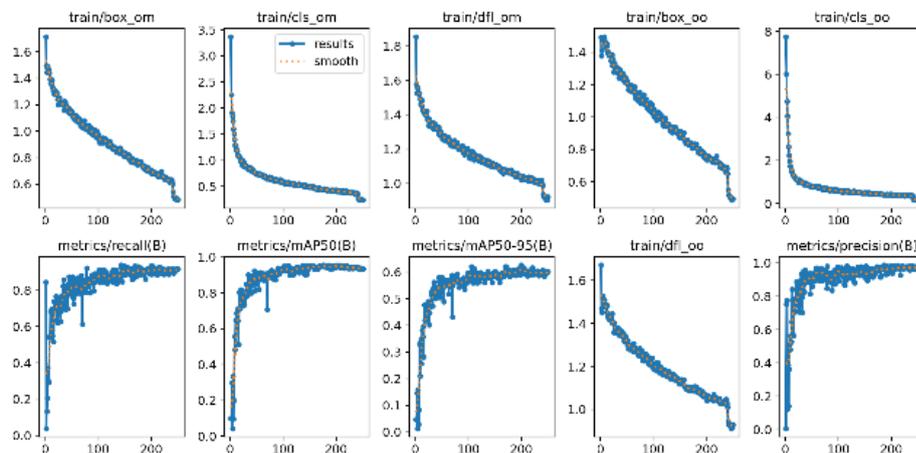
Pada penelitian ini, dilakukan sebanyak tiga eksperimen. Dalam setiap eksperimen, ukuran epoch yang berbeda digunakan, yaitu jumlah total iterasi pelatihan dalam eksperimen tersebut berbeda. Oleh karena itu, jumlah gambar dalam set pelatihan, validasi, dan pengujian bervariasi untuk setiap eksperimen sambil tetap mempertahankan rasio 69:20:11. Hasil dari eksperimen dapat dilihat pada Gambar 5, 6, dan 7.



Gambar 5. Hasil performa model YOLOv10 epoch 150



Gambar 6. Hasil performa model YOLOv10 epoch 200



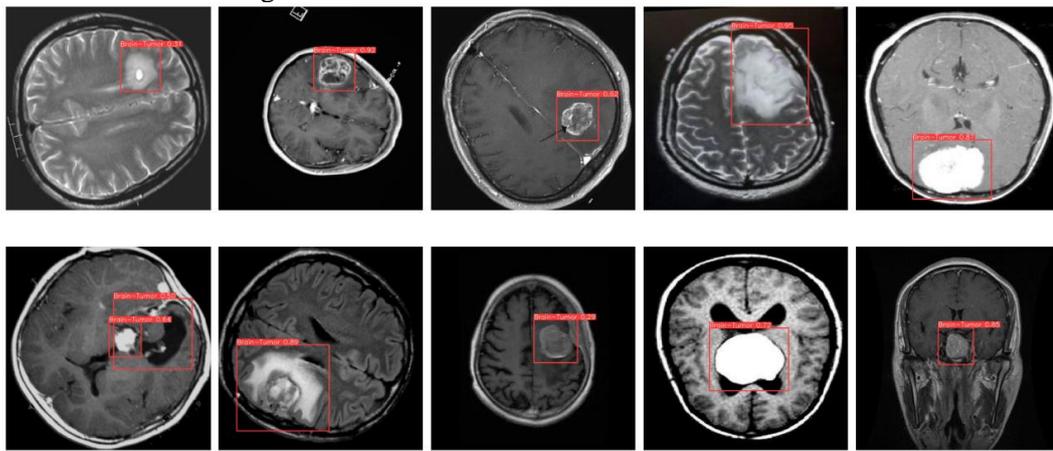
Gambar 7. Hasil performa model YOLOv10 epoch 250

Gambar 5, 6, dan 7 menggambarkan metrik kinerja YOLOv10 pada setiap eksperimen. Berdasarkan hasil pengujian, dapat diketahui bahwa pada epoch 150, model menunjukkan nilai train/box sebesar 0,60186, train/cls sebesar 0,28834, dan train/dfi sebesar 0,96209. Metrik precision mencapai 96,67%, recall 89,60%, dan mAP50 sebesar 92,24%. Meskipun hasil ini cukup baik, ada indikasi bahwa model belum mencapai performa optimal, terutama pada recall dan mAP50. Kemudian, pada epoch 200, model mengalami peningkatan performa dengan train/box sebesar 0,5225, train/cls sebesar 0,25734, dan train/dfi sebesar 0,93318. Metrik precision mencapai 97,88%, recall 95,24%, dan mAP50 sebesar 95,84%. Hasil ini menunjukkan bahwa model lebih stabil dan lebih akurat dalam mendeteksi tumor pada gambar MRI. Pada epoch 250, performa model sedikit menurun pada beberapa metrik, meskipun tetap cukup bersaing. Train/box mencapai 0,48335, train/cls 0,23845, dan train/dfi 0,92206. Precision mencapai 98,02%, recall menurun menjadi 91,73%, dan mAP50 menjadi 93,51%. Penurunan ini mungkin disebabkan oleh overfitting pada model, yang mulai kehilangan generalisasi ketika dilatih lebih lama. Berdasarkan hasil di atas, model terbaik didapatkan pada epoch 200, di mana model mencapai keseimbangan antara precision, recall, dan mAP50 yang optimal.

3. Pengujian Model

Dilakukan penelitian kualitatif untuk melengkapi evaluasi kuantitatif terhadap teknik yang telah diusulkan pada penelitian ini untuk mengidentifikasi tumor otak dari MRI. Pada

tahap akhir telah dipilih sepuluh gambar MRI acak dari dataset. Seperti yang dapat dilihat pada Gambar 8, penggunaan model YOLOv10 yang ditingkatkan menghasilkan hasil yang konsisten dan dapat diandalkan. Konsistensi model dalam berbagai pengaturan menunjukkan bahwa model ini dapat berguna dalam memantau dan mendeteksi tumor otak menggunakan MRI. Gambar 8 menunjukkan bahwa metode yang diusulkan pada penelitian ini, menggunakan model YOLOv10 yang ditingkatkan, sangat berhasil dalam mendeteksi kanker otak dalam berbagai kondisi. Gambar tumor besar dan kecil digunakan untuk menguji konsistensi metode kami. Untuk pencegahan dan pengobatan kanker otak yang efektif, diagnosis dini sangat penting (Ottom *et al.*, 2022). Hasil ini menunjukkan bahwa metode yang diusulkan menunjukkan potensi sebagai alat untuk memfasilitasi diagnosis tumor otak dan meningkatkan hasil deteksi.



Gambar 8. Pengujian model deteksi tumor pada MRI otak

KESIMPULAN

Penelitian ini berhasil mengembangkan model deteksi tumor otak pada gambar Magnetic Resonance Imaging (MRI) menggunakan arsitektur YOLOv10. Berdasarkan hasil pelatihan dan evaluasi yang telah dilakukan, model menunjukkan performa yang sangat baik dalam mendeteksi tumor otak, dengan metrik precision, recall, dan mAP yang cukup tinggi dengan kemampuan generalisasi yang baik pada dataset uji. Hasil penelitian menunjukkan bahwa model yang dilatih dengan 200 epoch memberikan hasil terbaik, dengan metrik precision mencapai sebesar 97,88%, recall 95,24%, dan mAP50 sebesar 95,84%. Meskipun performa model sedikit menurun pada epoch 250, terutama dalam hal recall dan mAP50, namun hasil keseluruhan menunjukkan bahwa YOLOv10 merupakan pilihan arsitektur yang efektif untuk tugas deteksi tumor otak pada gambar Magnetic Resonance Imaging (MRI).

Pada penelitian selanjutnya, disarankan untuk mengeksplorasi lebih lanjut penggunaan teknik prapemrosesan dan augmentasi data yang lebih beragam guna meningkatkan kualitas dan jumlah data latih, serta mempertimbangkan penerapan teknik transfer learning untuk meningkatkan performa model pada dataset yang lebih besar dan kompleks. Penelitian lebih lanjut dapat difokuskan pada pengujian model pada berbagai jenis modalitas MRI dan memvalidasi model dengan data dari berbagai institusi medis untuk memastikan kualitas model yang lebih baik. Penggunaan arsitektur YOLO yang lebih baru dan modifikasi arsitektur YOLOv10 juga bisa menjadi pertimbangan untuk mengevaluasi peningkatan performa serta dapat menjadi langkah lanjutan dalam mendukung diagnosis medis yang lebih cepat dan akurat.

DAFTAR PUSTAKA

- Ahmad, S. and Choudhury, P.K. (2022) 'On the Performance of Deep Transfer Learning Networks for Brain Tumor Detection Using MR Images', *IEEE Access*, pp. 59099–59114. Available at: <https://doi.org/10.1109/ACCESS.2022.3179376>.
- Akbar, F., Rais, A.N., Sobari, I.A., Zuama, R.A. and Rudiarto, B. (2019) 'Analisis Performa Algoritma Naive Bayes Pada Deteksi Otomatis Citra Mri', *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, pp. 37–42. Available at: <https://doi.org/10.33480/jitk.v5i1.586>.
- Aleid, A., Alhussaini, K., Alanazi, R., Altwaimi, M., Altwijri, O. and Saad, A.S. (2023) 'Artificial Intelligence Approach for Early Detection of Brain Tumors Using MRI Images', *Applied Sciences (Switzerland)*. Available at: <https://doi.org/10.3390/app13063808>.
- Anushkannan, N.K., Kumbhar, V.R., Maddila, S.K., Kolli, C.S., Vidhya, B. and Vidhya, R.G. (2022) 'YOLO Algorithm for Helmet Detection in Industries for Safety Purpose', *3rd International Conference on Smart Electronics and Communication, ICOSEC 2022 - Proceedings*, pp. 225–230. Available at: <https://doi.org/10.1109/ICOSEC54921.2022.9952154>.
- Asad, R., Rehman, S. ur, Imran, A., Li, J., Almuhaimeed, A. and Alzahrani, A. (2023) 'Computer-Aided Early Melanoma Brain-Tumor Detection Using Deep-Learning Approach', *Biomedicines*. Available at: <https://doi.org/10.3390/biomedicines11010184>.
- Astuti, L.W. (2019) 'Ekstrasi Fitur Citra MRI Otak Menggunakan Data Wavelet Transform (DWT) untuk Klasifikasi Penyakit Tumor Otak', *Jurnal Ilmiah Informatika Global*. Available at: <https://doi.org/10.36982/jig.v10i2.854>.
- Maharana, K., Mondal, S. and Nemade, B. (2022) 'A review: Data pre-processing and data augmentation techniques', *Global Transitions Proceedings*, pp. 91–99. Available at: <https://doi.org/10.1016/j.gltip.2022.04.020>.
- MRI, B. (2023) 'MRI Dataset'. Roboflow. Available at: <https://universe.roboflow.com/brain-mri/mri-rskcu>.
- Mulyana, D.I. and Rowis, M.A.I. (2022) 'Optimization of Text Mining Detection of Tajweed Reading Laws Using the Yolov8 Method on the Qur'an', *QALAMUNA: Jurnal Pendidikan, Sosial, dan Agama*, pp. 1089–1110. Available at: <https://doi.org/10.37680/qalamuna.v14i2.3866>.
- Musallam, A.S., Sherif, A.S. and Hussein, M.K. (2022) 'A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images', *IEEE Access*, pp. 2775–2782. Available at: <https://doi.org/10.1109/ACCESS.2022.3140289>.
- Ottom, M.A., Rahman, H.A. and Dinov, I.D. (2022) 'Deep learning approach for 2D MRI brain tumor segmentation'. IEEE. Available at: <https://doi.org/https://doi.org/10.1109/JTEHM.2022.3176737>.
- Padilla, R., Netto, S.L. and Da Silva, E.A.B. (2020) 'A Survey on Performance Metrics for Object-Detection Algorithms', *International Conference on Systems, Signals, and Image Processing*, pp. 237–242. Available at: <https://doi.org/10.1109/IWSSIP48289.2020.9145130>.

-
- Saraswathi, V. and Gupta, D. (2019) 'Classification of Brain Tumor using PCA-RF in MR Neurological Images', *2019 11th International Conference on Communication Systems and Networks, COMSNETS 2019*, pp. 440–443. Available at: <https://doi.org/10.1109/COMSNETS.2019.8711010>.
- Sung, H., Ferlay, J., Siegel, R.L., Laversanne, M., Soerjomataram, I., Jemal, A. and Bray, F. (2021) 'Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries', *CA: A Cancer Journal for Clinicians*, pp. 209–249. Available at: <https://doi.org/10.3322/caac.21660>.
- Tika, A.M. and Qudsiah, N.A. (2022) 'Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine', *Jurnal Infortech*, pp. 45–50. Available at: <https://ejournal.bsi.ac.id/ejurnal/index.php/infortech/article/view/12813>.
- Toufiq, D.M., Sagheer, A.M. and Veisi, H. (2021) 'A Review on Brain Tumor Classification in MRI Images', *Turkish Journal of Computer and Mathematics Education*, pp. 1958–1969.
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J. and Ding, G. (2024) 'YOLOv10: Real-Time End-to-End Object Detection'. Available at: <http://arxiv.org/abs/2405.14458>.
- Zoph, B., Cubuk, E.D., Ghiasi, G., Lin, T.Y., Shlens, J. and Le, Q. V. (2020) 'Learning Data Augmentation Strategies for Object Detection', *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 566–583. Available at: https://doi.org/10.1007/978-3-030-58583-9_34.