

# Sistem Berbasis *Deep Learning* untuk Segmentasi dan Klasifikasi Tingkat Keganasan Tumor Otak Menggunakan Citra MRI 3D

Indira Salsabila Ardan<sup>1</sup>, Rarasmaya Indraswari<sup>2,\*</sup>

Departemen Sistem Informasi, Fakultas Teknologi Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

<sup>1</sup>6026231019@student.its.ac.id; <sup>2</sup>raras@its.ac.id

\*penulis korespondensi

## INFO ARTIKEL

### Sejarah Artikel

Diterima: 5 Juli 2024

Direvisi: 28 Juli 2024

Diterbitkan: 13 Agustus 2024

### Kata Kunci

*Deep learning*

*Magnetic Resonance Imaging*

Segmentasi tumor otak

Tumor otak

## ABSTRAK

Tumor otak merupakan pertumbuhan sel abnormal di dalam otak, yang dapat bersifat jinak atau ganas. Kanker otak, yang merupakan bentuk ganas dari tumor otak, termasuk dalam jenis kanker yang paling agresif dan sering terdiagnosis pada berbagai rentang usia. Di Indonesia, terdapat sekitar 300 kasus tumor otak yang didiagnosis setiap tahunnya, termasuk pada anak-anak. Dalam menangani kasus tumor otak, diperlukan informasi mengenai lokasi spasial tumor dan tingkat keganasan tumor untuk merencanakan pembedahan dan pengobatan. Metode saat ini yang mengandalkan analisis manual pada citra *Magnetic Resonance Imaging* (MRI) dapat menyebabkan hasil yang bervariasi antar dokter (*inter-observer error*). Penelitian mengenai klasifikasi tingkat keganasan tumor otak pada citra MRI 3D juga masih terbatas. Oleh karena itu, dalam penelitian ini, akan dilakukan pengembangan sistem yang menggunakan metode *deep learning* untuk segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D. Dalam penelitian ini, telah berhasil dikembangkan sistem berbasis *deep learning* yang mampu melakukan segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D. Model segmentasi tumor otak yang diusulkan menggunakan arsitektur U-Net dengan *dice* sebesar 82% pada 250 *epoch*. Sedangkan, model klasifikasi yang diusulkan menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan *base model* ResNet50V2 yang sudah dilatih pada *dataset* ImageNet, *head model* yang terdiri dari satu lapisan *dense* dengan 512 *nodes*, dan lapisan *output* yang memprediksi *input* menjadi dua kelas, yaitu "LGG" dan "HGG" dengan *accuracy* sebesar 97% pada 10 *epoch*.

## PENDAHULUAN

Tumor otak merupakan pertumbuhan sel yang abnormal di dalam otak, yang dapat bersifat jinak atau ganas. Kanker otak, yang merupakan bentuk ganas dari tumor otak, termasuk dalam jenis kanker yang paling agresif dan sering terdiagnosis pada berbagai rentang usia [1]. Di Indonesia, terdapat sekitar 300 kasus tumor otak yang didiagnosis setiap tahunnya, termasuk pada anak-anak [2]. Dalam menangani kasus tumor otak, diperlukan informasi mengenai lokasi spasial tumor untuk merencanakan pembedahan dan pengobatan serta menilai dan memantau respons terhadap pengobatan [3]. Selain itu, informasi mengenai tingkat keganasan tumor juga diperlukan untuk membentuk rencana pengobatan dan, dalam beberapa kasus, untuk memperkirakan prognosis [4]. Dalam rangka melakukan diagnosis dengan lebih cepat dan memberikan informasi yang lebih komprehensif, telah dikembangkan metode pencitraan untuk mendeteksi tumor otak, salah satunya menggunakan *Magnetic Resonance Imaging* (MRI). MRI menggunakan medan magnet dan gelombang

radio yang dihasilkan oleh komputer untuk menghasilkan gambaran detail otak dalam kepala. Alat MRI berbentuk tabung yang dikelilingi oleh magnet besar melingkar. Pemeriksaan MRI menghasilkan citra tiga dimensi (3D) yang dapat dilihat dari berbagai sudut. Namun, segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI umumnya masih dilakukan secara manual oleh dokter spesialis, yang dapat menghasilkan hasil yang bervariasi antara satu dokter dan dokter lainnya (*inter-observer error*).

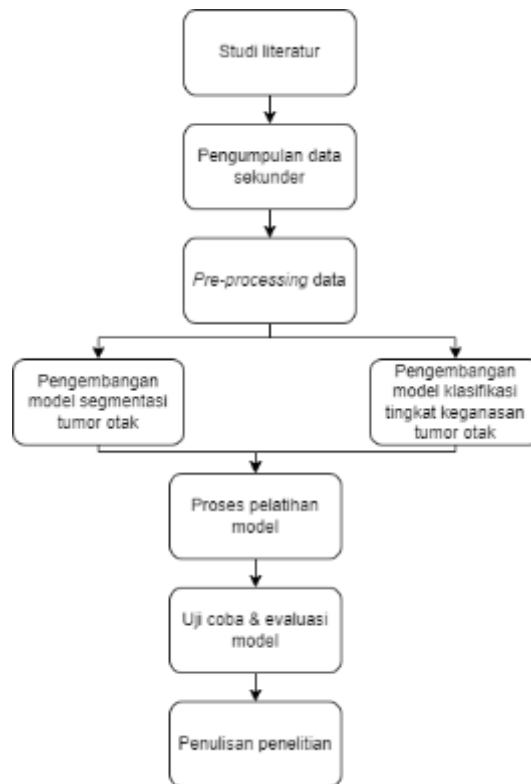
Beberapa penelitian telah dilakukan dalam bidang segmentasi tumor otak menggunakan metode *deep learning*. Ganesh dkk. (2019) menggunakan tiga arsitektur 3D-Dense-Unet untuk segmentasi tumor otak. Kelompok pertama menggunakan *dice* sebagai fungsi *loss*. Kelompok kedua menggunakan *binary focal loss* sebagai fungsi *loss*. Kelompok ketiga terdiri dari dua subkelompok, yaitu *High Grade Glioma* (HGG) dan *Low Grade Glioma* (LGG). Pada langkah pertama dari kelompok ketiga, sebuah jaringan *Convolutional Neural Network* (CNN) dikembangkan untuk memisahkan antara HGG dan LGG. Jaringan HGG dilatih menggunakan kasus HGG, sementara jaringan LGG dilatih menggunakan kasus LGG. Hasil eksperimen pada *dataset Brain Tumor Segmentation* (BraTS) 2019 memberikan nilai *dice* sebesar 85% [5]. Sun dkk. (2019) menggunakan *ensemble* dari tiga arsitektur CNN 3D yang berbeda, yaitu *Cascaded Anisotropic Convolutional Neural Network* (CA-CNN), DFKZ Net, dan 3D U-Net, untuk segmentasi tumor otak. Hasil eksperimen pada *dataset BraTS 2019* memberikan nilai *dice* sebesar 80% dan *Hausdorff Distance 95% percentile* (HD95) sekitar 3 mm [6]. Shboul dkk. (2019) menggunakan CNN, U-Net, dan *Fully Convolutional Network* (FCN), bersama dengan fitur radiomik untuk melakukan segmentasi tumor otak. Selain itu, *semantic label fusion* juga digunakan untuk meningkatkan akurasi segmentasi. Hasil eksperimen pada *dataset BraTS 2018* memberikan nilai *dice* sebesar 80% [7]. Feng dkk. (2020) menggunakan *ensemble* 3D U-Net untuk segmentasi tumor otak. Enam jaringan U-Net digunakan dengan konfigurasi yang berbeda, termasuk jumlah blok *encoding/decoding*, ukuran *input patch*, dan bobot berbeda untuk *loss*. Hasil eksperimen pada *dataset BraTS 2018* memberikan nilai *dice* sebesar 81% dan HD95 sekitar 17 mm [8]. Pei dkk. (2020) mengusulkan metode *Context-Aware Deep Neural Network* (CANet) untuk segmentasi tumor otak. Setelah itu, dengan memanfaatkan jaringan abnormal yang telah tersegmentasi, 3D CNN digunakan untuk mengklasifikasikan tingkat keganasan tumor ke dalam tiga kelas, yaitu *astrocytoma*, *IDH-mutant* (A), *oligodendroglioma*, *IDH-mutant* (O), dan *glioblastoma*, *IDH-wildtype* (G). Hasil eksperimen segmentasi pada *dataset BraTS2019* memberikan nilai *dice* sebesar 85% dengan HD95 sekitar 5 mm. Sementara itu, hasil eksperimen klasifikasi pada *dataset CPM-RadPath 2019* memberikan nilai *accuracy* sebesar 64% [9].

Meskipun telah banyak penelitian dilakukan untuk melakukan segmentasi tumor otak pada citra MRI 3D menggunakan metode *deep learning*, penelitian yang melakukan klasifikasi tingkat keganasan tumor otak masih terbatas. Oleh karena itu, dalam penelitian ini, akan dilakukan pengembangan sistem yang menggunakan metode *deep learning* untuk segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D. Dengan penelitian ini, diharapkan sistem yang dikembangkan dapat secara otomatis dan akurat melakukan segmentasi dan klasifikasi tingkat keganasan tumor otak.

## METODE

Penelitian ini dilakukan sesuai dengan Gambar 1 yang melibatkan beberapa tahapan. Pertama, studi literatur yang mendukung pengerjaan penelitian sebagai acuan dan dasar dalam melakukan penelitian. Kedua, pengumpulan data sekunder. Ketiga, *pre-processing* data, dengan mengubah format citra dari NiftI (.nii) menjadi format JPG (.jpg), untuk mempermudah visualisasi dan analisis. Keempat, pengembangan model segmentasi tumor otak dan pengembangan model klasifikasi tingkat keganasan tumor otak, menggunakan


arsitektur yang diusulkan. Kelima, proses pelatihan model. Keenam, uji coba & evaluasi model untuk mencapai performa yang optimal. Terakhir, penulisan penelitian.



Gambar 1. Metode penelitian

### **Dataset**

*Dataset* yang digunakan pada penelitian ini berasal dari *dataset* BraTS 2020 [10], [11], [12]. Setiap citra pada *dataset* berukuran 240 x 240 piksel dan terdiri dari 155 *slice*, dengan total 369 kasus. Kasus tersebut terdiri dari 76 kasus LGG dan 293 kasus HGG. Setiap kasus dilengkapi dengan empat modalitas MRI: FLAIR, T1, T2, dan T1CE, serta *ground truth* segmentasi dari jaringan abnormal pada tumor. *Ground truth* segmentasi diperoleh melalui segmentasi manual oleh satu hingga empat penilai, diverifikasi oleh ahli radiologi saraf berpengalaman, dan mencakup *Gadolinium-Enhancing Tumor* (ET), *Peritumoral Edema* (ED), dan *Necrotic and Non-Enhancing Tumor Core* (NCR/NET). Data tersebut akan dibagi menjadi set pelatihan dan pengujian dengan rasio 80:20. Gambar 2 menunjukkan contoh citra dalam *dataset*.

Gambar 2. Contoh citra dalam *dataset*

### Pre-processing Data

Implementasi ke dalam *coding* dilakukan untuk menyesuaikan data agar dapat diolah oleh jaringan *deep learning*. Pemrosesan dilakukan pada citra dengan mengubah format dari NifTI (.nii) menjadi JPG (.jpg) untuk memudahkan visualisasi dan analisis. Ekstraksi informasi dilakukan dari setiap *slice* pada gambar 3D dan disimpan sebagai gambar 2D.

### Model Segmentasi Tumor Otak

Arsitektur U-Net digunakan dalam model segmentasi tumor otak pada penelitian ini. Model ini menerima citra *input* berukuran 112 x 112 piksel dan menghasilkan *output* yang sesuai dengan *ground truth* sebesar 112 x 112 piksel. Model ini dilatih dari awal, artinya proses pelatihan dimulai menggunakan data BraTS2020 tanpa menggunakan model yang dilatih sebelumnya. Dalam proses ini, arsitektur jaringan dan semua parameter diinisialisasi secara acak sebelum memulai proses pelatihan.

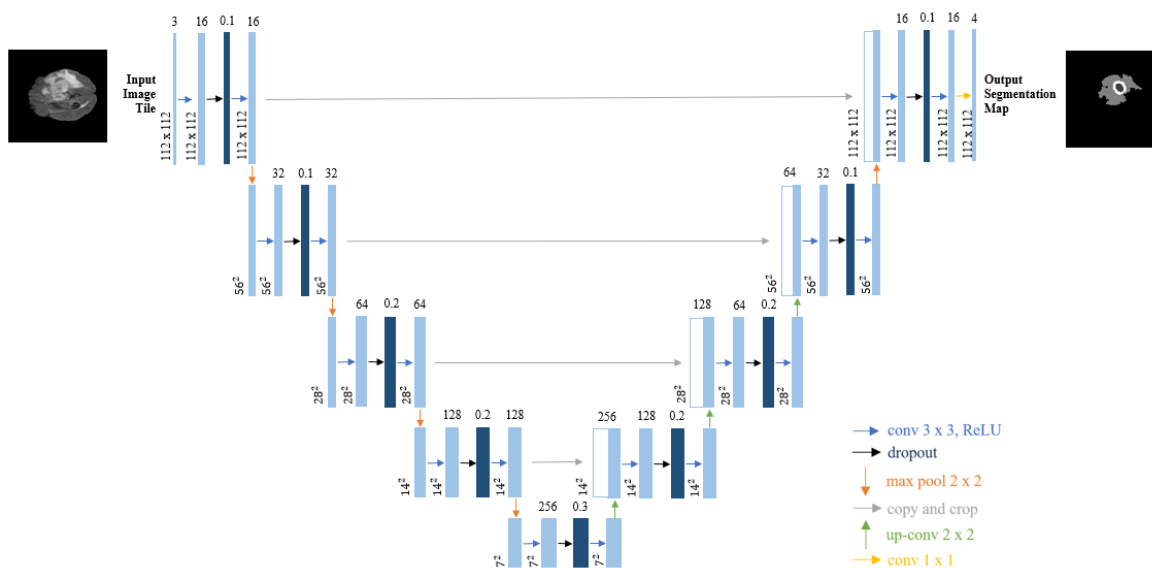
U-Net merupakan metode *deep learning* yang paling banyak digunakan untuk segmentasi citra, terutama dalam konteks citra medis [13]. U-Net mengadopsi pendekatan *end-to-end* sepenuhnya, yang artinya bekerja dari awal hingga akhir tanpa memerlukan langkah tambahan, menggunakan *convolutional network*. Secara umum, arsitektur U-Net terdiri dari dua lapisan utama, yaitu *encoder (downsampling)* dan *decoder (upsampling)* [14].

Lapisan *encoder* bertujuan untuk mengurangi resolusi citra dan menangkap informasi global dari citra. Lapisan ini terdiri dari lima blok. Setiap blok dimulai dengan dua lapisan konvolusi untuk mengekstraksi fitur dengan jumlah *filter* berturut-turut 16, 32, 64, 128, dan 256. Setiap lapisan konvolusi menggunakan *kernel* berukuran 3 x 3 piksel dengan fungsi aktivasi ReLU dan menggunakan *padding 'same'*. Jumlah *filter (feature channel)* digandakan untuk mempertahankan representasi fitur yang penting pada tingkat resolusi yang lebih rendah. Di antara kedua lapisan konvolusi tersebut, digunakan lapisan *dropout* untuk mengurangi *overfitting*, dengan tingkat *dropout* masing-masing 0.1, 0.1, 0.2, 0.2, dan 0.3. Terakhir, lapisan *max pooling* digunakan untuk mengurangi dimensi hasil konvolusi dengan *window* berukuran 2 x 2 piksel pada setiap blok. *Output* dari *encoder* adalah representasi fitur penting dengan ukuran yang lebih kecil dari citra input, yang akan digunakan sebagai input untuk *decoder*.

Lapisan *decoder* bertujuan untuk mengembalikan informasi spasial yang mungkin hilang selama proses *downsampling*. Lapisan ini terdiri dari empat blok. Setiap blok dimulai dengan lapisan konvolusi *transpose* untuk memperbesar dimensi fitur secara bertahap. Jumlah *filter* yang digunakan adalah 128, 64, 32, dan 16 secara berturut-turut, dengan *kernel* berukuran 2 x 2 piksel, kecuali pada blok terakhir yang menggunakan ukuran 3 x 3 piksel, serta menggunakan langkah *strides* dan *padding 'same'*. Fitur-fitur yang telah diperbesar

kemudian digabungkan dengan representasi fitur dari *encoder* yang sesuai menggunakan lapisan *concatenate*. Tujuannya adalah untuk mempertahankan informasi detail dari *encoder*. Kemudian, dua lapisan konvolusi digunakan dengan *kernel* berukuran 3 x 3 piksel dan fungsi aktivasi ReLU untuk mengolah fitur yang telah digabungkan. Di antara kedua lapisan konvolusi tersebut, digunakan lapisan *dropout* untuk mengurangi *overfitting*, dengan tingkat *dropout* 0.2 pada blok pertama dan kedua, serta 0.1 pada blok ketiga dan keempat. Terakhir, lapisan konvolusi dengan jumlah *filter* sesuai dengan jumlah kelas, yaitu 4, dan fungsi aktivasi softmax digunakan untuk menghasilkan *output* berupa citra hasil segmentasi tumor.

Arsitektur U-Net dapat diterapkan pada citra baik dua dimensi (2D) maupun tiga dimensi (3D). Perbedaan utamanya terletak pada jenis matriks konvolusi yang digunakan. Pada citra 2D, digunakan matriks konvolusi dua dimensi (disebut 2D U-Net), sementara pada citra 3D, digunakan matriks konvolusi tiga dimensi (disebut 3D U-Net). Model segmentasi tumor otak dalam penelitian ini dilatih menggunakan algoritma optimasi Adam dengan *batch size* 128 untuk 250 *epoch*. Gambar 3 menunjukkan arsitektur model segmentasi tumor otak yang diusulkan.



Gambar 3. Arsitektur model segmentasi tumor otak yang diusulkan

### Model Klasifikasi Tingkat Keganasan Tumor Otak


Pada penelitian ini, arsitektur CNN digunakan dalam model klasifikasi tingkat keganasan tumor otak. CNN adalah metode *deep learning* yang paling umum digunakan untuk mengklasifikasikan citra. CNN menggunakan potongan kecil citra (*image patch*) untuk mengklasifikasikan piksel-piksel dalam citra. Namun, kelemahan dari metode ini adalah proses konvolusi yang dilakukan berulang kali dengan potongan piksel yang saling bertumpang-tindih.

Penggunaan metode *deep learning*, termasuk CNN, telah meningkat karena mampu memberikan akurasi yang tinggi dalam pengolahan citra. Namun, ada beberapa permasalahan yang muncul dalam segmentasi citra medis 3D menggunakan metode *deep learning*, seperti jumlah data pelatihan yang sedikit, sumber daya komputasi yang terbatas, dan ketidakseimbangan *dataset*. Beberapa strategi telah dikembangkan untuk mengatasi masalah ini, seperti pemrosesan 3D menggunakan kernel 3D dan pemrosesan 2D dengan *slicing* citra.

Secara umum, CNN terdiri dari tiga jenis lapisan atau proses. Lapisan pertama adalah lapisan konvolusi, di mana fungsi aktivasi ReLU digunakan untuk melakukan konvolusi 2D dan menghasilkan beberapa *channel* atau *feature map* [15]. Lapisan kedua adalah lapisan *pooling*, yang digunakan untuk mengompresi citra dan mendapatkan fitur utama dengan ukuran *window* tertentu. Lapisan terakhir adalah lapisan *fully-connected* (*dense layer*), yang serupa dengan metode *Artificial Neural Network* (ANN) dan digunakan untuk menghasilkan nilai *output* dan melakukan proses pelatihan dengan menggunakan *cost function*.

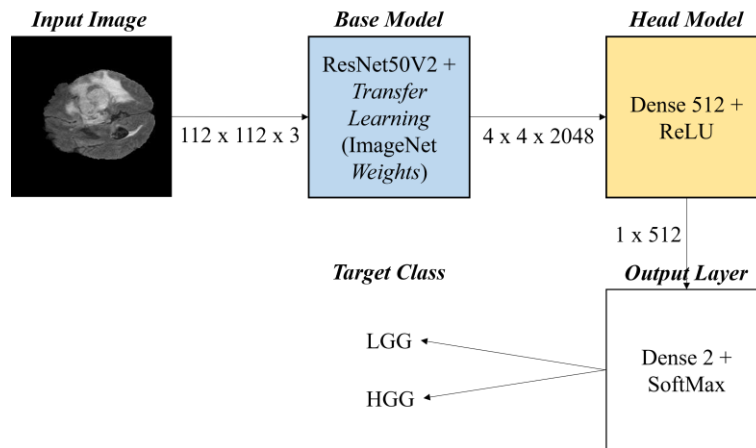
Dalam proses pelatihan CNN, *error* antara hasil klasifikasi dan label data digunakan untuk memperbarui nilai *filter* konvolusi di jaringan. Proses ini bertujuan untuk meningkatkan akurasi klasifikasi dan disebut proses pelatihan atau *training*. ResNet50V2 digunakan sebagai *base model* pada model klasifikasi tingkat keganasan tumor otak. ResNet50V2 adalah salah satu varian populer dari arsitektur ResNet (*Residual Network*) yang dikembangkan pada tahun 2015 untuk pengolahan citra. Arsitektur ini terdiri dari 50 lapisan konvolusi yang membuatnya sangat efektif dalam melakukan klasifikasi citra. Salah satu fitur utama dari ResNet50V2 adalah penggunaan fitur *skip connections* atau *shortcut connections*. Fitur ini memungkinkan jaringan untuk mempelajari *residual functions*, yaitu perbedaan antara *input* dan *output* pada setiap lapisan.

Keunggulan utama dari fitur *skip connections* pada ResNet50V2 adalah kemampuannya dalam mengatasi masalah penurunan kinerja (*vanishing gradient*). Masalah ini terjadi ketika *gradient*, yang merupakan turunan parsial dari fungsi *error* terhadap bobot jaringan, menjadi sangat kecil atau bahkan menghilang saat dilakukan *back-propagation* pada lapisan-lapisan dalam jaringan. Dengan adanya *skip connections*, jaringan dapat lebih mudah mempelajari *residual functions*, sehingga masalah *gradient* yang menghilang dapat diatasi. Hal ini berdampak positif pada peningkatan kinerja jaringan dalam mempelajari dan mengekstraksi fitur-fitur yang kompleks dari citra. Gambar 4 menunjukkan Arsitektur ResNet50V2.



Gambar 4. Arsitektur ResNet50V2 [16]

Gambar MRI otak dari *dataset* BraTS2020 diubah ukurannya menjadi  $112 \times 112 \times 3$  piksel untuk konsistensi. Lapisan *output* ResNet50V2 telah dihapus dan semua lapisan dibekukan. *Head model* kemudian ditempatkan di atas lapisan *base model*, dengan fungsi aktivasi ReLU untuk memproses *head model* melalui lapisan *dense* 512 *nodes* setelah menerima *feature map* berukuran  $4 \times 4 \times 2048$  *channels* dari *base model*. Lapisan *output* terdiri dari 2 *nodes* dengan fungsi aktivasi Softmax untuk mengklasifikasikan kelas “LGG” dan “HGG” dari citra MRI otak. Model dilatih menggunakan algoritma optimasi Adam, dengan *batch size* 32, selama 10 *epoch*, dan menggunakan *Synthetic Minority Oversampling Technique* (SMOTE) untuk menangani ketidakseimbangan data. Gambar 5 menunjukkan arsitektur model klasifikasi tingkat keganasan tumor otak yang diusulkan.



Gambar 5. Arsitektur model klasifikasi tingkat keganasan tumor otak yang diusulkan

## HASIL DAN PEMBAHASAN

Dalam penelitian ini, model yang diusulkan diimplementasikan menggunakan bahasa pemrograman Python dan *library* TensorFlow-Keras. Eksperimen dilakukan menggunakan GPU NVIDIA GeForce RTX 3060 dan RAM 32 GB 3600 MHz DDR4.

### Eksperimen pada Model Segmentasi Tumor Otak

Pada model segmentasi tumor otak, dilakukan eksperimen terhadap jumlah *epoch* yang digunakan untuk menemukan model dengan performa terbaik. Jumlah *epoch* yang dibandingkan adalah 50, 100, 150, 200, 250, dan 300 *epoch*. Metrik evaluasi yang digunakan adalah *dice*, yang mengevaluasi tumpang tindih antara hasil prediksi segmentasi dan *ground truth*. Perbandingan dibatasi hingga 300 *epoch* dikarenakan terjadi penurunan performa model ketika jumlah *epoch* ditingkatkan dari 250 menjadi 350, sehingga tidak ada peningkatan performa yang diharapkan. Berdasarkan hasil eksperimen yang ditunjukkan pada Tabel 1, ditemukan bahwa model dengan jumlah *epoch* sebanyak 250 menghasilkan performa terbaik.

Tabel 1. Eksperimen jumlah *epoch* untuk model segmentasi tumor otak

Jumlah <i>epoch</i>	Performa model (%)	
	<i>Dice</i>	<i>Running time</i> (detik)
50	76	<b>12154</b>
100	80	24304
150	80	36443
200	81	48963
<b>250 (Usulan)</b>	<b>82</b>	60744
300	81	72896

Model segmentasi tumor otak yang diusulkan dalam penelitian ini mencapai *dice* sebesar 82% dengan *running time* 60744 detik. Secara keseluruhan, performa model ini cukup baik meskipun menggunakan ukuran citra *input* yang lebih rendah dibandingkan penelitian sebelumnya. Keterbatasan komputasi membatasi ukuran citra *input* menjadi 112 x 112 x 3 piksel. Meskipun ukuran citra *input* dalam penelitian ini lebih rendah, perbedaan performa model tidak terlalu signifikan dibandingkan dengan penelitian sebelumnya.

### Eksperimen pada Model Klasifikasi Tingkat Keganasan Tumor Otak

Pada model klasifikasi tingkat keganasan tumor otak, dilakukan dua eksperimen untuk menemukan model dengan performa terbaik. Metrik evaluasi yang digunakan mencakup *accuracy*, yang mengukur rasio antara prediksi benar dengan jumlah keseluruhan data; *precision*, yang mengukur rasio prediksi benar positif terhadap keseluruhan hasil yang diprediksi positif; *recall*, yang mengukur prediksi benar positif terhadap keseluruhan data yang sebenarnya positif; dan *f1-score*, yang merupakan perbandingan rata-rata antara presisi dan recall yang diwakili dengan bobot tertentu.

Pertama, dilakukan perbandingan antar arsitektur *base model* yang digunakan untuk *transfer learning*. *Transfer learning* merupakan teknik di mana model yang telah dilatih sebelumnya digunakan sebagai titik awal untuk pelatihan pada tugas baru. Arsitektur *base model* yang dibandingkan adalah ResNet50V2 [16], InceptionResNetV2 [17], dan MobileNetV2 [18]. Dalam penelitian ini, seluruh *base model* yang digunakan telah dilatih pada *dataset* ImageNet. Semua eksperimen menggunakan arsitektur *head model* yang sama, yang terdiri dari satu lapisan *dense* dengan 512 *nodes* [19]. Berdasarkan hasil eksperimen yang ditunjukkan pada Tabel 2, ditemukan bahwa arsitektur *base model* ResNet50V2 menghasilkan model dengan performa terbaik.

Tabel 2. Eksperimen *base model* untuk model klasifikasi tingkat keganasan tumor otak

Arsitektur <i>base model</i>	Performa model (%)				<i>Running time</i> (detik)
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	
ResNet50V2 [16] <b>(Usulan)</b>	<b>97</b>	<b>97</b>	<b>97</b>	<b>97</b>	1168
InceptionResNetV2 [17]	92	94	92	92	1521
MobileNetV2 [18]	95	96	95	95	<b>1084</b>

Kedua, dilakukan perbandingan antar jumlah *epoch* yang digunakan. Jumlah *epoch* yang dibandingkan adalah 10, 20, dan 30. Perbandingan dibatasi hingga 30 *epoch* dikarenakan tidak terjadi peningkatan performa model saat jumlah *epoch* ditingkatkan dari 10 ke 20 dan performa menurun saat jumlah *epoch* ditingkatkan dari 20 ke 30, sehingga tidak ada peningkatan performa yang diharapkan. Berdasarkan hasil eksperimen yang ditunjukkan pada Tabel 3, ditemukan bahwa model dengan jumlah *epoch* sebanyak 10 menghasilkan performa terbaik. Selain itu, jumlah *epoch* yang lebih rendah ini memberikan *running time* yang paling efisien sehingga lebih menguntungkan dari segi waktu pelatihan.

Tabel 3. Eksperimen jumlah *epoch* untuk model klasifikasi tingkat keganasan tumor otak

Jumlah <i>epoch</i>	Performa model (%)				<i>Running time</i> (detik)
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	
10 <b>(Usulan)</b>	<b>97</b>	<b>97</b>	<b>97</b>	<b>97</b>	<b>1168</b>
20	97	97	97	97	1693
30	96	96	96	96	2044

Model klasifikasi tingkat keganasan tumor otak yang diusulkan dalam penelitian ini mencapai *accuracy*, *precision*, *recall*, dan *f1-score* sebesar 97%, dengan *running time* 1168 detik. Performa model ini sangat baik untuk membedakan antara kelas “LGG” dan “HGG” pada citra MRI 3D. Hal ini menunjukkan bahwa model mampu menangkap karakteristik penting dari kedua tingkat keganasan tumor tersebut.

## KESIMPULAN

Dalam penelitian ini, telah berhasil dikembangkan sistem berbasis *deep learning* yang mampu melakukan segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D. Model segmentasi tumor otak yang diusulkan menggunakan arsitektur U-Net dengan *input* berupa *dataset* citra MRI otak berukuran 112 x 112 piksel dan *output* berupa citra yang telah tersegmentasi berukuran 112 x 112 piksel. Dengan menggunakan model yang diusulkan, diperoleh *dice* sebesar 82%, yang mencapai performa terbaiknya pada 250 *epoch*. Model klasifikasi tingkat keganasan tumor otak yang diusulkan menggunakan metode CNN dengan arsitektur yang terdiri dari *base model*, *head model*, dan lapisan *output*. *Base model* yang digunakan adalah ResNet50V2 yang telah dilatih terlebih dahulu (*pre-trained*) pada *dataset* ImageNet. Citra MRI berukuran 112 x 112 x 3 piksel digunakan sebagai *input*, sedangkan output-nya berukuran 4 x 4 x 2048 *channels*. *Head model* yang digunakan terdiri dari satu lapisan *dense* dengan 512 *nodes* dan menggunakan fungsi aktivasi ReLU. Lapisan tersebut langsung terhubung dengan lapisan *output* yang memprediksi input berupa 512 *nodes* ke dalam dua kelas, yaitu "LGG" dan "HGG", dengan menggunakan fungsi aktivasi softmax. Dengan menggunakan model yang diusulkan, diperoleh *accuracy*, *precision*, *recall*, dan *f1 score* sebesar 97%, yang mencapai performa terbaiknya pada 10 *epoch*. Untuk penelitian selanjutnya, dapat dilakukan pengembangan arsitektur jaringan guna meningkatkan performa model dalam segmentasi dan klasifikasi tingkat keganasan tumor otak. Selain itu, penggunaan *dataset* yang lebih besar dapat digunakan untuk menguji kinerja model.

## REFERENSI

- [1] R. Vankdothu, M. A. Hameed, and H. Fatima, "A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method," *Computers and Electrical Engineering*, vol. 101, p. 107960, Jul. 2022, doi: 10.1016/J.COMPELECENG.2022.107960.
- [2] UNAIR News, "Pentingnya Peran Perawat Kesehatan di Rumah bagi Pasien Tumor Otak." Accessed: Oct. 03, 2023. [Online]. Available: <https://news.unair.ac.id/2019/04/29/pentingnya-peran-perawat-kesehatan-di-rumah-bagi-pasien-tumor-otak/?lang=id><https://news.unair.ac.id/2019/04/29/pentingnya-peran-perawat-kesehatan-di-rumah-bagi-pasien-tumor-otak/?lang=id>
- [3] A. Fathi Kazerooni et al., "Automated Tumor Segmentation and Brain Tissue Extraction from Multiparametric MRI of Pediatric Brain Tumors: A Multi-Institutional Study," *medRxiv*, vol. 5, no. 1, Jan. 2023, doi: 10.1101/2023.01.02.22284037.
- [4] National Cancer Institute, "Tumor Grade - NCI." Accessed: Jul. 03, 2024. [Online]. Available: <https://www.cancer.gov/about-cancer/diagnosis-staging/diagnosis/tumor-grade>
- [5] C. Ganesh et al., "Fully Automated Brain Tumor Segmentation and Survival Prediction of Gliomas using Deep Learning and MRI," *bioRxiv*, p. 760157, Oct. 2019, doi: 10.1101/760157.
- [6] L. Sun, S. Zhang, H. Chen, and L. Luo, "Brain Tumor Segmentation and Survival Prediction Using Multimodal MRI Scans With Deep Learning," *Frontiers in Neuroscience*, vol. 13, no. JUL, p. 810, 2019, doi: 10.3389/FNINS.2019.00810.
- [7] Z. A. Shboul, M. Alam, L. Vidyaratne, L. Pei, M. I. Elbakary, and K. M. Iftekharuddin, "Feature-Guided Deep Radiomics for Glioblastoma Patient Survival Prediction," *Frontiers in Neuroscience*, vol. 13, Sep. 2019, doi: 10.3389/FNINS.2019.00966.
- [8] X. Feng, N. J. Tustison, S. H. Patel, and C. H. Meyer, "Brain Tumor Segmentation Using an Ensemble of 3D U-Nets and Overall Survival Prediction Using Radiomic Features," *Frontiers in computational neuroscience*, vol. 14, Apr. 2020, doi: 10.3389/FNCOM.2020.00025.
- [9] L. Pei, L. Vidyaratne, M. M. Rahman, and K. M. Iftekharuddin, "Context aware deep learning for brain tumor segmentation, subtype classification, and survival prediction using radiology images," *Scientific reports*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/S41598-020-74419-9.
- [10] S. Bakas et al., "Advancing The Cancer Genome Atlas glioma MRI collections with expert

- segmentation labels and radiomic features,” *Scientific Data* 2017 4:1, vol. 4, no. 1, pp. 1–13, Sep. 2017, doi: 10.1038/sdata.2017.117.
- [11] S. Bakas et al., “Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge,” Nov. 2018.
- [12] B. H. Menze et al., “The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS),” *IEEE Transactions on Medical Imaging*, vol. 34, no. 10, pp. 1993–2024, Oct. 2015, doi: 10.1109/TMI.2014.2377694.
- [13] N. Siddique, S. Paheding, C. P. Elkin, and V. Devabhaktuni, “U-net and its variants for medical image segmentation: A review of theory and applications,” *IEEE Access*, 2021, doi: 10.1109/ACCESS.2021.3086020.
- [14] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Verlag, 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4\_28.
- [15] A. F. Agarap, “Deep Learning using Rectified Linear Units (ReLU),” Mar. 2018, Accessed: Nov. 02, 2023. [Online]. Available: <https://arxiv.org/abs/1803.08375v2>
- [16] K. He, X. Zhang, S. Ren, and J. Sun, “Identity Mappings in Deep Residual Networks,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9908 LNCS, pp. 630–645, Mar. 2016, doi: 10.1007/978-3-319-46493-0\_38.
- [17] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning,” *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 31, no. 1, pp. 4278–4284, Feb. 2017, doi: 10.1609/AAAI.V31I1.11231.
- [18] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 4510–4520, Jan. 2018, doi: 10.1109/CVPR.2018.00474.
- [19] I. S. Ardan and R. Indraswari, “Design of Brain Tumor Detection System on MRI Image Using CNN,” *2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems, ICETISIS 2024*, pp. 1388–1393, 2024, doi: 10.1109/ICETISIS61505.2024.10459651.