

# Segmentasi Tumor Otak Berdasarkan Citra Magnetic Resonance Imaging Dengan Menggunakan Metode U-NET

Ida Bagus Leo Mahadya Suta<sup>1</sup>, Made Sudarma<sup>2</sup>, I Nyoman Satya Kumara<sup>3</sup>

[Submission: 11-02-2020, Accepted: 13-11-2020]

**Abstract**—Brain tumor is a deadly disease where 3.7% per 100,000 patients have malignant tumors. To analyze brain tumors can be done through magnetic resonance imaging (MRI) image segmentation. Automatic image analysis process is needed to save time and improve accuracy of doctor diagnoses. Automatic segmentation can be done with deep learning. U-NET is one of the methods used to segment medical images because it works at pixel level. By applying the ReLU and Adam Optimizer activation function, this method can solve the problem of segmenting brain tumors. Dataset for the training and validation process using BRATS 2017. Several hyperparameters are applied to this method: learning rate ( $lr$ ) = 0.0001, batch size ( $bz$ ) = 5, epoch = 80 and beta ( $b_1$ ) = 0.9. From a series of processes carried out, accuracy of the U-NET method is calculated by Dice Coefficient formula and results in following accuracy values, during training of 90.22% (Full Tumor), 78.09% (Core Tumor) and 80.20% (Enhancing Tumor).

**Intisari**—Salah satu penyakit yang paling mematikan adalah tumor otak dengan tingkat kematian mencapai 3.7% per 100.000 pasien. Untuk menganalisa tumor otak dapat dilakukan melalui segmentasi citra *Magnetic Resonance Imaging* (MRI). Proses analisa citra secara otomatis dibutuhkan untuk menghemat waktu dan meningkatkan akurasi dari diagnosa yang dilakukan. Segmentasi secara otomatis dapat dilakukan dengan *deep learning*. Khusus pada citra medis metode yang digunakan harus mampu bekerja pada *pixel level* agar dapat mencapai akurasi yang baik, salah satu metode tersebut adalah metode U-NET. Dengan menerapkan fungsi aktivasi ReLU dan Adam Optimizer, metode ini dapat menyelesaikan permasalahan segmentasi tumor otak. Dataset untuk proses *training* dan *validation* menggunakan BRATS 2017. Beberapa *hyperparameter* diterapkan pada metode ini yaitu, *learning rate* ( $lr$ ) = 0.0001, *batch size* ( $bz$ ) = 5, *epoch* = 80 dan *beta* ( $b_1$ ) = 0.9. Dari serangkaian proses yang dilakukan, akurasi metode U-NET dihitung dengan rumus *Dice Coefficient* dan menghasilkan nilai akurasi sebagai berikut: 90.22% (Full Tumor), 78.09% (Core Tumor) dan 80.20% (Enhancing Tumor).

**Kata Kunci**—Tumor Otak, MRI, citra medis, deep learning, U-Net, ReLU, Adam Optimizer, Training, Validation

## I. PENDAHULUAN

<sup>1</sup>Mahasiswa, Magister Teknik Elektro Universitas Udayana Gedung Pascasarjana Universitas Udayana, Jl. PB Sudirman Denpasar-Bali 80232 (telp: 0361-555225; fax: 0361-4321982; e-mail: [gusleo.bali@gmail.com](mailto:gusleo.bali@gmail.com))

<sup>2,3</sup>Dosen, Magister Teknik Elektro Universitas Udayana Gedung Pascasarjana Universitas Udayana, Jl. PB Sudirman Denpasar-Bali 80232 (telp: 0361-555225; fax: 0361-4321982; e-mail: [msudarma@unud.ac.id](mailto:msudarma@unud.ac.id), [satya.kumara@unud.ac.id](mailto:satya.kumara@unud.ac.id))




baik. Namun, hal tersebut berdampak pada waktu penyelesaian metode relatif lebih lama. Dalam penelitian ini [21] menawarkan metode U-NET CNN yang mampu bekerja pada *pixel level* dan memanfaatkan fungsi aktivasi ReLU dan berhasil memberikan akurasi yang baik dan waktu penyelesaian yang lebih singkat pada gambar sel mikroskopis. Sehingga, pada penelitian ini akan menggunakan metode U-NET dalam segmentasi citra biomedis MRI tumor otak.

II. STUDI LITERATUR

A. Tumor Otak


Pertumbuhan sel yang tidak normal dan tidak terkendali pada otak merupakan penyebab tumor otak. Jenis tumor otak yang paling umum ditemukan adalah Glioma yang memiliki tingkat kematian yang tinggi. Glioma dibagi menjadi dua jenis, yaitu *High Grade Glioma* (HGG) dan *Low Grade Glioma* (LGG). Umumnya, pasien yang menderita HGG memiliki harapan hidup yang lebih rendah dibandingkan dengan LGG. Biasanya, pasien yang menderita LGG memiliki harapan hidup antara 6 sampai 15 tahun, namun pasien yang menderita HGG hanya memiliki harapan hidup sekitar 15 bulan [22].



Gambar 1: (a) Otak Normal, (b) *Low Grade Glioma*, (c) *High Grade Glioma*

B. U-Net Convolutional Neural Network

CNN merupakan pengembangan dari ANN dan terdiri dari *neuron* yang memiliki bobot, *bias* dan fungsi aktivasi. CNN memiliki *convolution*, *pooling* dan *fully connected layer* [23]–[26]. Citra *input* akan menghasilkan *output* dari proses konvolusi, pada tahapan ini disebut dengan *Convolution Layer*. Proses konvolusi mengekstrak fitur dari citra input, proses konvolusi menggunakan fungsi aktivasi untuk menentukan jaringan yang aktif atau tidak. Pada penelitian ini fungsi aktivasi yang digunakan adalah fungsi nonlinier ReLU. Aktivasi ReLU (*Rectified Linear Unit*) merupakan *layer* aktivasi yang mengaplikasikan fungsi  $R(x) = \max(0, z)$  yang artinya fungsi ini melakukan filterisasi dengan nilai nol terhadap nilai bobot pada citra *input*. Gambar 2 menunjukkan aktivasi ReLU, dimana untuk setiap bobot dengan nilai minus akan dirubah menjadi nilai bobot nol.




Gambar 2 Fungsi Aktivasi Non-Linier ReLU

Proses selanjutnya adalah *pooling layer*, *Pooling layer* memiliki tujuan untuk mengurangi ukuran sebuah citra. Selain itu *Pooling* juga dapat meningkatkan invariasi posisi dari fitur. *Max pooling* dan *average pooling* adalah metode yang biasa digunakan pada proses ini [23].

Agar dapat diklasifikasikan secara linier, transformasi data satu dimensi dilakukan pada tahapan *fully connected layer* dengan cara menjumlahkan *weight input* dan nilai *bias* kemudian mengaplikasikannya kedalam fungsi aktivasi ReLU. Untuk memperoleh nilai rentang probabilitas fungsi *softmax* akan diterapkan. Jumlah propabilitas yang dihasilkan sama dengan satu dengan rentang antara 0 sampai 1.

Arsitektur U-Net dibangun di atas *Fully Convolutional Network* (FCN) dan dimodifikasi sedemikian rupa sehingga menghasilkan segmentasi yang lebih baik dalam pencitraan medis. Dibandingkan dengan FCN, dua perbedaan utamanya adalah (1) U-NET simetris dan (2) koneksi lompatan (*skip connection*) antara jalur *downsampling* dan jalur *upsampling* yang menerapkan operator gabungan daripada penjumlahan. *Skip connection* ini bertujuan untuk memberikan informasi lokal ke informasi global selama *upsampling*. Karena simetris, jaringan memiliki sejumlah besar *feature map* di jalur *upsampling*, yang memungkinkan untuk mentransfer informasi. Sebagai perbandingan, arsitektur FCN dasar hanya memiliki sejumlah peta fitur kelas di jalur *upsampling*-nya.



Gambar 3. Arsitektur U-NET  
Sumber: Diambil dari [21]

Gambar 3 menggambarkan arsitektur U-NET yang dibagi menjadi 3 bagian:

1. Jalur *contracting/downsaming*
2. *Bottleneck*
3. Jalur *expanding/upsampling*

*Contracting* atau *downsaming* terdiri dari 4 blok, dan setiap blok tersusun atas

- 3x3 *Convolution Layer* + fungsi aktivasi
- 3x3 *Convolution Layer* + fungsi aktivasi
- 2x2 *Max Pooling*

Perlu diperhatikan bahwa jumlah *feature map* akan berlipat ganda untuk setiap *pooling*, dimulai dengan 64 *feature map* pada blok pertama, 128 untuk blok kedua dan seterusnya. *Contracting* bertujuan untuk menangkap konteks gambar input agar dapat melakukan segmentasi. Informasi kontekstual kasar ini kemudian akan ditransfer ke jalur *upsampling* dengan cara *skip connection*.

*Bottleneck* adalah bagian yang terdapat di antara jalur *upsampling* dan *downsampling*. *Bottleneck* dibangun dari hanya 2 *convolutional layer* (dengan *batch normalization*).

*Expanding* atau *Upsampling* memiliki tujuan untuk memungkinkan lokalisasi yang tepat dikombinasikan dengan informasi kontekstual dari jalur *contracting*. Terdiri dari 4 blok dan setiap blok terdiri dari:

- *Deconvolution layer* dengan 2 *stride*
- Penggabungan dengan *feature map* yang dipotong dari jalur *contracting*
- 3x3 *Convolution Layer* + fungsi aktivasi (dengan normalisasi *batch*)
- 3x3 *Convolution Layer* + fungsi aktivasi (dengan normalisasi *batch*)

### III. METODELOGI PENELITIAN

#### A. Sumber Data

Penelitian ini menggunakan data primer yang berasal dari Multi Brain Tumor Image Segmentation (BRATS) 2017. BRATS 2017 memiliki citra MRI dari 210 pasien yang menderita tumor otak HGG dan 75 pasien tumor otak LGG yang akan dibagi menjadi 20% data *validation* dan 80% data *training*. Data multimodal MRI tersedia dengan 4 urutan pemindaian untuk setiap pasien, yaitu T1-weighted (T1), citra T1-weighted dengan penambahan kontras gadolinium (T1c), T2-weighted (T2) dan *Fluid Attenuated Inversion Recovery* (FLAIR). Selain itu, segmentasi manual dengan empat kelas intra-tumoral tersedia untuk setiap pasien; (1) *necrosis*, (2) *edema*, (3) *non-enhancing*, (4) *enhancing tumor*. Segmentasi manual ini digunakan sebagai dasar kebenaran pengujian (*ground truth*) dalam segmentasi model pada saat *training* maupun pada saat *validation*.

#### B. Gambaran Umum Sistem

Diagram blok berikut adalah gambaran umum dari alur proses sistem diagnosa tumor otak berdasarkan citra MRI yang dapat dilihat pada gambar 4.

Gambar 4. Gambaran Umum Sistem

Pada alur diagram diatas, dapat dilihat sebuah citra MRI sebelum diproses oleh algoritma U-NET akan melalui beberapa tahapan terlebih dahulu. Diawali dengan proses *bias correction* N4ITK untuk menghilangkan *noise* yang ada pada citra MRI, tahapan ini sangat berguna untuk meminimalisir kesalahan pada proses klasifikasi. Kemudian dilakukan proses *data augmentation* untuk memperbanyak dataset, dalam penelitian ini proses *augmentation* yang dilakukan dengan *flip vertical* dan *flip horizontal*. Algoritma U-NET akan melakukan proses pembelajaran melalui fase *training* dan

*validation*, sehingga menghasilkan Data Model. Data model adalah kumpulan dataset citra MRI tumor otak yang telah diolah sebelumnya oleh algoritma U-NET, untuk menghasilkan kumpulan data *array* yang tersimpan sebagai data pembelajaran. Selanjutnya, algoritma U-NET akan mensegmentasi citra inputan dan menentukan wilayah tumor otak.

Selama pengujian berlangsung akurasi dan *loss* akan dihitung setiap perulangan (*epoch*) dengan menggunakan rumus *Dice Coefficient*. *Dice Coefficient* merupakan ukuran *overlap* antara dua sampel. Ukuran ini berkisar dari 0 sampai 1, dimana *Dice Coefficient* bernilai 1 adalah yang terbaik. Fungsi ini awalnya dikembangkan untuk data biner dan dapat dihitung berdasarkan rumus berikut:

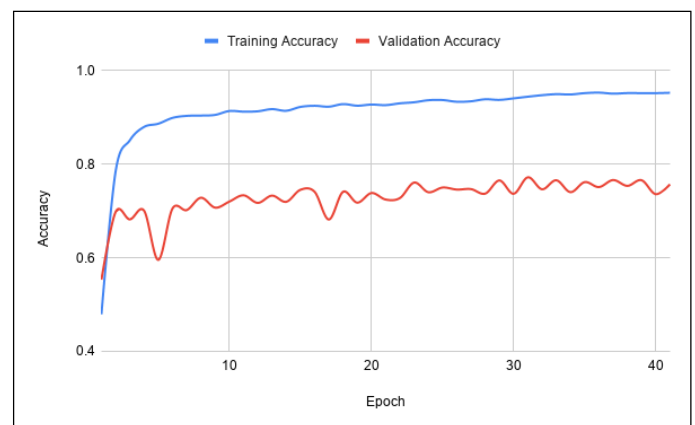
$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

Dimana  $|A \cap B|$  mewakili elemen antara set A dan B,  $|A|$  mewakili jumlah elemen dalam set A dan  $|B|$  mewakili jumlah elemen dalam set B. Sedangkan untuk menghitung *loss* atau kesalahan yang dihasilkan oleh model ini, kami menggunakan fungsi *Soft Dice Coefficient* yang menggunakan perhitungan  $1 - Dice$ .

### IV. HASIL DAN PEMBAHASAN


Pengujian dilakukan dengan menggunakan dataset BRATS 2017, yang dibagi menjadi dataset *training* dan *validation* dengan rasio 80:20. Pada algoritma U-Net yang akan diujikan, terdapat beberapa *hyperparameter* dan juga *parameter* pada fungsi optimasi *Adam Optimizer*. Adapun nilai pada *hyperparameter* adalah sebagai berikut, *learning rate* ( $lr$ ) = 0.0001, *batch size* ( $bz$ ) = 5, *epoch* = 80 dan *beta* ( $b_1$ ) = 0.9.

Matrik evaluasi dibagi menjadi tiga wilayah tumor yang bernama a) *Complete/Full Tumor* (*necrosis*, *edema*, *enhancing* dan *non enhancing tumor*), wilayah kedua adalah *Core Tumor* (sama seperti *Complete Tumor* tanpa *edema*) dan yang terakhir adalah *Enhancing Tumor*.




Gambar 5. Grafik Perbandingan Akurasi Fase *Training* dan *Validation* Pada Proses Segmentasi *Full Tumor*







Gambar 6. Grafik Perbandingan Loss Fase *Training* dan *Validation* Pada Proses Segmentasi *Full Tumor*



Gambar 9. Grafik Perbandingan Akurasi Fase *Training* dan *Validation* Pada Proses Segmentasi *ET Tumor*



Gambar 7. Grafik Perbandingan Akurasi Fase *Training* dan *Validation* Pada Proses Segmentasi *Core Tumor*



Gambar 10. Grafik Perbandingan Loss Selama Fase *Validation* dan *Testing* Pada Proses Segmentasi *ET Tumor*



Gambar 8. Grafik Perbandingan Loss Fase *Training* dan *Validation* Pada Proses Segmentasi *Core Tumor*

Berdasarkan Gambar 5 - 10, menunjukkan bahwa grafik dari model U-Net tidak menunjukkan kondisi *overfitting* maupun *underfitting*, melainkan menuju pada grafik yang menuju konvergen. *Underfitting* merupakan kejadian dimana model yang telah terbentuk tidak mampu untuk melihat logika dibalik *dataset*, sehingga model tidak dapat melakukan prediksi dengan hasil yang akurat pada data *training* maupun data *validation*. Sedangkan *Overfitting* terjadi ketika model yang dibuat terlalu fokus pada *training dataset* tertentu, sehingga tidak bisa melakukan prediksi dengan benar apabila diberikan *dataset* lain yang serupa. Dalam penelitian ini jumlah *epoch* = 80, namun karena keterbatasan perangkat, peneliti menerapkan *early stop monitor*. *Early stop monitor* merupakan kondisi dimana fase *training* dihentikan sebelum keseluruhan *epoch* selesai. Kondisi yang diterapkan adalah, apabila dalam setiap 10 *epoch* terjadi penurunan akurasi maka fase *training* akan dihentikan.

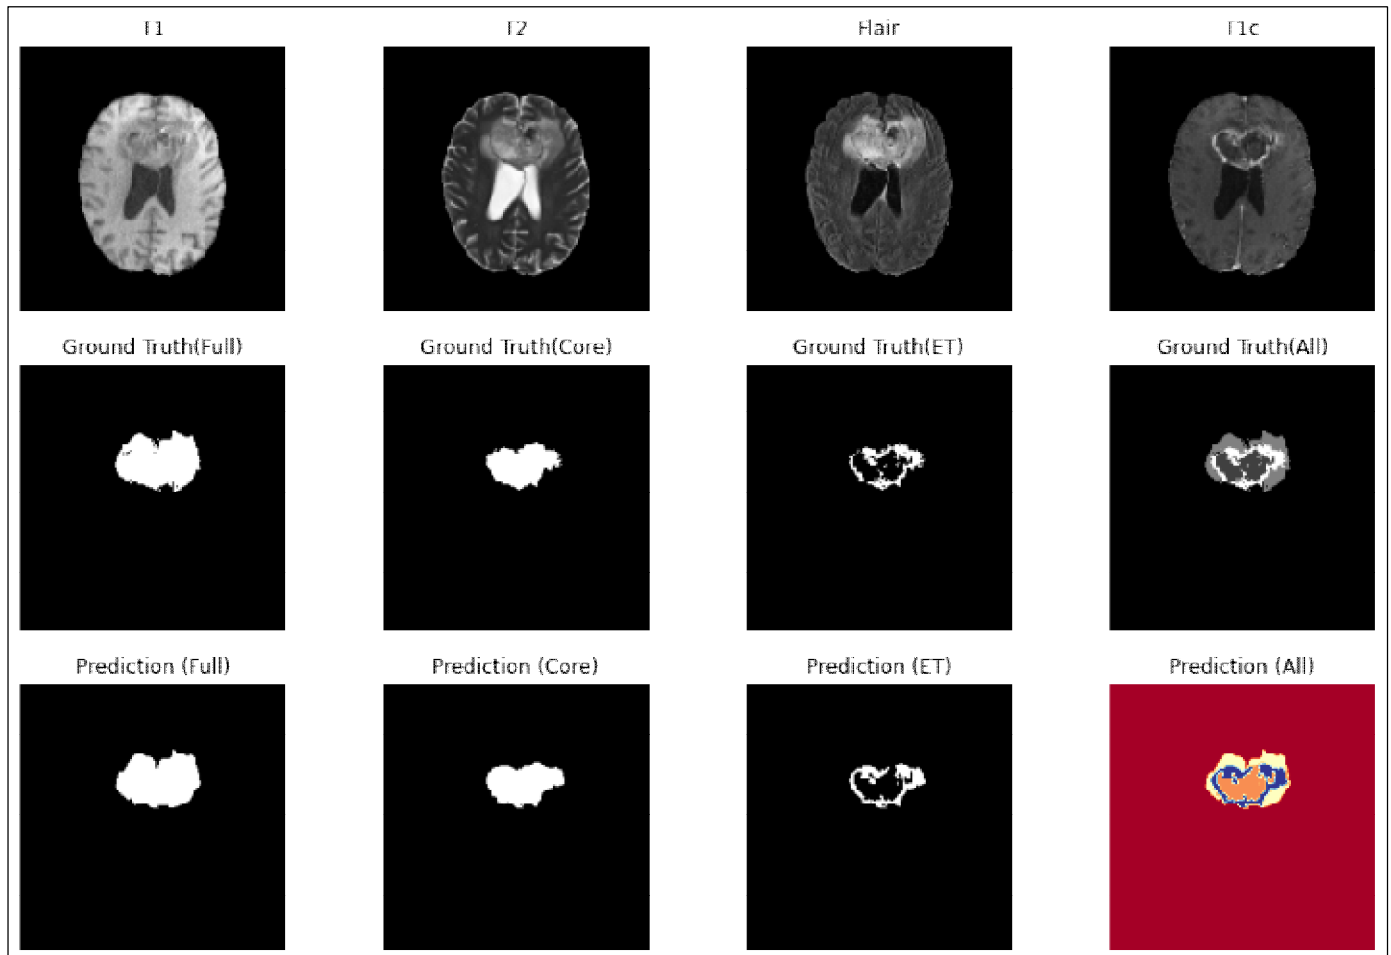
Ketika proses pembelajaran segmentasi *full tumor*, metode U-NET tidak mengalami peningkatan akurasi pada *epoch* ke-47, sehingga U-NET berhenti pada *epoch* tersebut. Kondisi yang sama ditunjukkan juga ketika melakukan proses pembelajaran pada wilayah *core tumor* yang tidak mengalami peningkatan akurasi pada *epoch* ke-47 yang menyebabkan proses pembelajaran terhenti pada *epoch* tersebut. Pada *enhancing tumor* terhenti pada *epoch* ke-73. Proses selanjutnya dengan melakukan evaluasi masing masing model yang

dihasilkan dengan menggunakan fungsi *model.evaluate()* sehingga mengetahui rata-rata akurasi dan *loss* yang dihasilkan.

Berdasarkan Tabel I, proses segmentasi *Full Tumor* memperoleh hasil akurasi yang paling tinggi dibandingkan dengan yang lainnya dikarenakan area tumornya paling besar dan paling jelas dibandingkan dengan area tumor lainnya. Gambar 11 menunjukkan hasil prediksi segmentasi tumor otak yang dibandingkan dengan segmentasi manual dari dokter. Dapat dilihat bahwa hasil segmentasi otomatis memberikan kemiripan yang tinggi dengan segmentasi manual.

TABEL I  
UHASIL AKURASI DAN LOSS SELAMA PENELITIAN

Segmentasi	Epoch	Accuracy	Loss
Full Tumor	41	90.22%	0.1
Core Tumor	47	78.09%	0.22
Enhancing Tumor	74	80.20%	0.2



Gambar 11 Hasil Prediksi Dari Model U-NET Dengan Fungsi Aktivasi ReLU

### V. KESIMPULAN

Berdasarkan pengujian yang dilakukan dan hasil yang ditunjukkan pada Tabel I, nilai akurasi pada saat validasi untuk *full tumor*, *core tumor* dan *enhancing tumor* berturut-turut adalah sebagai berikut: 90.22%, 78.09%, 80.20%.

Untuk penelitian selanjutnya, disarankan agar merubah fungsi optimasi seperti LReLU, PReLU atau ELU serta menambah variasi *data augmentation* (rotasi, *shift*, *blur* dan sebagainya) untuk memperkaya *dataset* dengan harapan dapat memperbaiki hasil akurasi untuk permasalahan segmentasi citra tumor otak.

### REFERENSI

Ida Bagus Leo Mahadya Suta: Segmentasi Tumor Otak Berdasarkan...

- [1] D. Ph *et al.*, "Brain Tumor Epidemiology: Consensus from the Brain Tumor Epidemiology Consortium (BTEC)," *NIH Public Access*, vol. 113, no. 1, pp. 1953–1968, 2010.
- [2] R. Riley, J. Murphy, and T. Higgins, "MRI imaging in pediatric appendicitis," *J. Pediatr. Surg. Case Reports*, vol. 31, no. January, pp. 88–89, 2018.
- [3] I. Bagus, L. Mahadya, R. S. Hartati, and Y. Divayana, "Diagnosis Tumor Otak Berdasarkan Citra MRI (Magnetic Resonance Imaging)," *Maj. Ilm. Teknol. Elektro*, vol. 18, no. 2, pp. 149–154, 2019.
- [4] Tech Wire Asia, "Medical diagnosis AI in Beijing beats real doctors," *Tech Wire Asia*, 2018. [Online]. Available: <https://techwireasia.com/2018/07/medical-diagnosis-ai-in-beijing-beats-real-doctors/>.
- [5] P. P. Winangun, I. M. O. Widyantara, and R. S. Hartati, "Learning Machine dengan Kernel Linear untuk Mengklasifikasi Kelainan Paru-Paru," *Maj. Ilm. Teknol. Elektro*, vol. 19, no. 1, pp. 83–88,

p-ISSN:1693 – 2951; e-ISSN: 2503-2372



9 772503 237146

- 2020.
- [6] A. Pinto, H. Correia, J. Oliveira, D. M. L. D. Rasteiro, and C. A. Silva, "Brain Tumour Segmentation based on Extremely Randomized Forest with High-Level Features," pp. 3037–3040, 2015.
- [7] N. Subbanna, D. Precup, and T. Arbel, "Iterative multilevel MRF leveraging context and voxel information for brain tumour segmentation in MRI," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 400–405, 2014.
- [8] M. Soltaninejad *et al.*, "Automated brain tumour detection and segmentation using superpixel-based extremely randomized trees in FLAIR MRI," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 12, no. 2, pp. 183–203, 2017.
- [9] W. Wu, A. Y. C. Chen, L. Zhao, and J. J. Corso, "Brain tumor detection and segmentation in a CRF (conditional random fields) framework with pixel-pairwise affinity and superpixel-level features," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 9, no. 2, pp. 241–253, 2014.
- [10] S. Shen, W. A. Sandham, M. H. Granat, M. F. Dempsey, and J. Patterson, "A New Approach to Brain Tumour Diagnosis Using Fuzzy Logic Based Genetic Programming," in *Proceedings of the 25th Annual International Conference of the IEEE EMBS*, 2004, vol. 1, pp. 870–873.
- [11] A. Das and M. Bhattacharya, "A study on prognosis of brain tumors using fuzzy logic and genetic algorithm based techniques," in *Proceedings - 2009 International Joint Conference on Bioinformatics, Systems Biology and Intelligent Computing, IJCBS 2009*, 2009, no. 1, pp. 348–351.
- [12] L. Szilagyi, L. Lefkovits, and B. Benyo, "Automatic Brain Tumor Segmentation in multispectral MRI volumes using a fuzzy c-means cascade algorithm," *2015 12th Int. Conf. Fuzzy Syst. Knowl. Discov. FSKD 2015*, pp. 285–291, 2016.
- [13] J. Belghese and S. Agustin, "Brain Tumor Segmentation using Pattern Neural Networks with MRI Images," *IJSTE -International J. Sci. Technol. Eng.*, vol. 3, no. 09, pp. 641–644, 2017.
- [14] S. Singh, "Classification of Human Brain Tumors from MRI Using K-NN Algorithm," *Int. J. Adv. Sci. Eng. Technol.*, vol. 3, no. 1, pp. 34–37, 2015.
- [15] R. M. Azawi and I. T. Ibrahim, "A Hybrid Approach for Classification of MRI Brain Tumors Using Genetic Algorithm , K-Nearest Neighbor and Probabilistic Neural Network," *Int. J. Comput. Sci. Inf. Secur.*, vol. 16, no. 5, pp. 74–85, 2018.
- [16] A. Arora, P. Roy, S. Venkatesan, and R. Babu, "k-NN Based Classification of Brain MRI Images using DWT and PCA to Detect Different Types of Brain Tumour," *Int. J. Med. Res. Heal. Sci.*, vol. 6, no. 9, pp. 15–20, 2017.
- [17] W. Mengqiao, Y. Jie, C. Yilei, and W. Hao, "The multimodal brain tumor image segmentation based on convolutional neural networks," *2017 2nd IEEE Int. Conf. Comput. Intell. Appl.*, pp. 336–339, 2017.
- [18] S. Hussain, S. M. Anwar, and M. Majid, "Brain Tumor Segmentation using Cascaded Deep Convolutional Neural Network," *39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, pp. 1998–2001, 2017.
- [19] A. Pinto, V. Alves, and C. A. Silva, "Brain Tumor Segmentation using Convolutional Neural Networks in MRI Images," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1240–1251, 2016.
- [20] J. W. Ha *et al.*, "Predicting high-risk prognosis from diagnostic histories of adult disease patients via deep recurrent neural networks," *2017 IEEE Int. Conf. Big Data Smart Comput. BigComp 2017*, pp. 394–399, 2017.
- [21] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9351, pp. 234–241, 2015.
- [22] L. Dirven, N. K. Aaronson, J. J. Heimans, and M. J. B. Taphoorn, "Health-related quality of life in high-grade glioma patients," *Chin. J. Cancer*, vol. 33, no. 1, pp. 40–45, 2014.
- [23] W. Rawat, "Deep Convolutional Neural Networks for Image Classification : A Comprehensive Review," vol. 2449, pp. 2352–2449, 2017.
- [24] G. Ö. Yiğit and B. M. Özyildirim, "Comparison of convolutional neural network models for food image classification," vol. 1839, 2018.
- [25] N. Sharma, V. Jain, and A. Mishra, "An Analysis of Convolutional Neural Networks for Image Classification," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 377–384, 2018.
- [26] N. M. Balasooriya and R. D. Nawarathna, "A sophisticated convolutional neural network model for brain tumor classification," *2017 IEEE Int. Conf. Ind. Inf. Syst.*, pp. 1–5, 2017.