

SEGMENTASI TUMOR OTAK PADA CITRA MRI MENGGUNAKAN SQUEEZE-AND-EXCITATION U-NET DENGAN PRAPROSES CLAHE

Jonathan Felix Levid, Meiriyama

Teknik Informatika, Universitas Multi Data Palembang
Jalan Rajawali No. 14 Palembang, Indonesia
Jonathanfelixlevid_2226250044@mhs.mdp.ac.id

ABSTRAK

Segmentasi tumor otak pada citra *Magnetic Resonance Imaging* (MRI) merupakan prosedur diagnosis vital, namun sering terkendala oleh kontras citra yang rendah dan batas tumor yang kabur sehingga menyulitkan model standar seperti U-Net. Penelitian ini bertujuan meningkatkan akurasi segmentasi melalui pendekatan hibrida yang menggabungkan prapemrosesan *Contrast-Limited Adaptive Histogram Equalization* (CLAHE) untuk mempertegas fitur lokal, dengan arsitektur *Squeeze-and-Excitation U-Net* (SE U-Net) yang merekalibrasi bobot fitur secara adaptif. Metode ini diterapkan pada dataset publik berisi 3064 citra MRI yang dibagi menjadi data latih, validasi, dan uji, dengan model dilatih selama 50 *epoch* menggunakan augmentasi data. Hasil pengujian menunjukkan bahwa integrasi CLAHE dan SE U-Net efektif menangani variabilitas morfologi tumor, menghasilkan kinerja yang andal dengan nilai *Dice Similarity Coefficient* (DSC) sebesar 0.82 dan *Intersection over Union* (IoU) sebesar 0.70 pada data validasi. Capaian ini membuktikan bahwa sinergi antara optimasi input dan mekanisme atensi mampu menghasilkan segmentasi medis otomatis yang presisi dan konsisten.

Kata kunci: Segmentasi Tumor Otak, MRI, U-Net, Squeeze and Excitation, CLAHE

1. PENDAHULUAN

Tumor otak merupakan salah satu penyakit mematikan yang disebabkan oleh pertumbuhan sel abnormal di dalam jaringan otak, sehingga deteksi dini dan diagnosis yang akurat sangat krusial untuk menentukan rencana pengobatan yang tepat, seperti pembedahan, radioterapi, atau kemoterapi. Saat ini, *Magnetic Resonance Imaging* (MRI) menjadi pencitraan standar emas dalam diagnosis klinis karena kemampuan memvisualisasikan struktur jaringan lunak dengan resolusi tinggi tanpa menggunakan radiasi ionisasi [3], [13]. Tahapan vital dalam analisis citra MRI adalah segmentasi, yang bertujuan untuk memisahkan area tumor dari jaringan otak sehat di sekitarnya guna pengukuran volume dan lokalisasi yang presisi [9]. Namun, segmentasi manual oleh ahli radiologi memakan waktu, melelahkan, dan bersifat subjektif, sehingga sistem segmentasi otomatis berbasis *Deep Learning*, khususnya arsitektur U-Net, telah banyak dikembangkan sebagai solusi standar [12].

Meskipun U-Net memiliki keunggulan dalam menangkap konteks spasial, arsitektur ini sering terkendala oleh kualitas citra MRI yang rendah akibat noise dan kontras yang minim antara jaringan tumor dan jaringan sehat, yang menyebabkan batas tumor menjadi kabur [11]. Selain itu, operasi konvolusi standar pada U-Net memperlakukan semua fitur pada channel dengan bobot yang sama, padahal tidak semua fitur relevan untuk proses segmentasi, yang sering kali berujung pada kesalahan prediksi [10]. Beberapa penelitian terdahulu telah mencoba mengatasi tantangan ini melalui dua pendekatan berbeda yaitu perbaikan kualitas input menggunakan teknik prapemrosesan *Contrast-Limited Adaptive Histogram Equalization* (CLAHE) mampu mempertegas detail

lokal dan batas tumor secara signifikan [11]. Di sisi lain, integrasi mekanisme atensi pada arsitektur jaringan juga terbukti efektif dengan mengembangkan varian U-Net dengan modul atensi yang mampu merekalibrasi bobot fitur secara adaptif, sehingga model dapat lebih fokus pada area tumor yang relevan [8], [10]. Hal ini menunjukkan bahwa penambahan Squeeze-and-Excitation (SE) berhasil meningkatkan performa segmentasi pada objek dengan morfologi yang kompleks [2].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan pendekatan hibrida yang menggabungkan prapemrosesan CLAHE dengan arsitektur Squeeze-and-Excitation U-Net (SE U-Net). Sinergi ini dirancang untuk mengatasi dua kelemahan utama yaitu CLAHE berfungsi memperbaiki kontras citra input agar batas tumor lebih tegas, sementara modul SE pada U-Net bertugas meningkatkan selektivitas model terhadap fitur-fitur penting. Dengan demikian, metode yang diusulkan diharapkan mampu menghasilkan segmentasi medis otomatis yang lebih presisi dan konsisten dibandingkan model U-Net standar.


2. TINJAUAN PUSTAKA

2.1. Tumor Otak

Tumor otak adalah pertumbuhan sel abnormal yang terjadi di dalam otak, yang bersifat jinak maupun ganas. Deteksi dini serta diagnosis yang saksama sangat penting untuk menaikkan prognosis serta peluang kesembuhan pasien. Salah satu tahap kunci pada analisis citra MRI adalah segmentasi, yaitu proses untuk melokalisasi dan memisahkan area tumor dari jaringan otak sehat di sekitarnya [2].

2.2. Contrast Limited Adaptive Histogram Equalization

CLAHE adalah salah satu tahapan pra-pemrosesan yang bertujuan untuk meningkatkan kualitas gambar agar mudah dipahami oleh model. CLAHE bekerja dengan membagi gambar menjadi beberapa bagian kecil untuk meningkatkan kontras disetiap bagian secara terpisah [2]. CLAHE memiliki mekanisme pembatas kontras untuk memastikan noise tidak diperkuat, sehingga detail batas antara tumor otak dan jaringan otak menjadi lebih tajam.



Gambar 1. Diagram CLAHE

Berdasarkan Gambar 1 [7], diagram tersebut mengilustrasikan alur kerja metode CLAHE yang dimulai dengan membagi citra input menjadi blok-blok kecil. Pada setiap blok, histogram dihitung dan diratakan untuk meningkatkan kontras secara lokal. Fitur utama dari metode ini adalah penerapan batas kliping yang berfungsi membatasi amplifikasi kontras berlebih, sehingga mencegah peningkatan noise pada area gambar yang seragam. Hasil akhirnya adalah citra dengan detail tepi yang lebih tajam dan kontras yang lebih seimbang [1].

Rumus dasar Histogram Equalization yang menjadi fondasi CLAHE melibatkan perhitungan Probabilitas (P) dan Fungsi Distribusi Kumulatif (CDF) sebagai berikut [1]:

Fungsi Kepadatan Probabilitas :

$$P_X(i) = p(x = i) = \frac{n_i}{n} \quad (1)$$

Fungsi Distribusi Kumulatif :

$$cdf_x(i) = \sum_{j=0}^i p(x = j) \quad (2)$$


Transformasi Level Keabuan :

$$h(v) = \text{round} \left(\frac{cdf(v) - cdf_{min}}{n - cdf_{min}} \right) \quad (3)$$

2.3. U-Net

U-Net adalah arsitektur dalam Convolutional Neural Network (CNN) yang berbentuk seperti huruf "U", terdiri dari jalur encoder dan decoder [6]. U-Net

dilengkapi dengan skip connection yang menggabungkan fitur dari encoder ke decoder untuk mempertahankan detail spasial penting [9].




Gambar 2. Arsitektur U-Net

Dari Gambar 2 yang bersumber dari [4], dapat dilihat struktur arsitektur U-Net yang memiliki bentuk simetris menyerupai huruf "U". Sisi kiri diagram menunjukkan jalur encoder (contracting path) yang terdiri dari operasi konvolusi dan max pooling untuk menangkap konteks fitur dari citra. Sisi kanan menunjukkan jalur decoder (expanding path) yang melakukan upsampling untuk mengembalikan resolusi spasial citra. Panah abu-abu melintang merepresentasikan skip connection, yang bertugas mentransfer fitur detail dari lapisan encoder ke lapisan decoder yang bersesuaian, sehingga informasi spasial penting tidak hilang selama proses downsampling.

2.4. Squeeze and Excitation

Squeeze and Excitation adalah modul atensi ringan yang ditambahkan untuk merekalibrasi bobot fitur secara adaptif. SE terdiri dari dua operasi utama: Squeeze yang merangkum informasi global menggunakan Global Average Pooling, dan Excitation yang menghitung skor kepentingan setiap channel menggunakan lapisan Fully Connected (FC) [8].



Gambar 3 Diagram Squeeze and Excitation

Squeeze :

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{l=1}^H \sum_{j=1}^W u_c(i, j) \quad (4)$$

Excitation :

$$s = F_{ez}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (5)$$

2.5. Penelitian Terdahulu

Sejumlah penelitian telah dilaksanakan untuk mengoptimalkan akurasi segmentasi tumor otak pada citra MRI, baik melalui inovasi arsitektur Deep Learning maupun optimalisasi teknik pra-pemrosesan citra. Hingga saat ini, arsitektur U-Net tetap menjadi

fondasi utama bagi berbagai pengembangan metode mutakhir karena keunggulannya dalam menangkap konteks spasial sekaligus mempertahankan detail fitur lokal.

Pengembangan signifikan pada arsitektur U-Net dilakukan oleh Prasanna dkk [1] yang memperkenalkan model *Squeeze Excitation Embedded Attention U-Net (SEEA-UNet)*. Penelitian ini mengintegrasikan mekanisme *Attention Gate* untuk memusatkan fokus model pada lokasi spasial tumor, serta menyisipkan *Squeeze-and-Excitation* pada jalur encoder untuk ekstraksi informasi krusial di tingkat channel. Hal ini menunjukkan bahwa integrasi mekanisme atensi ganda ini mampu meningkatkan kinerja model secara efektif dibandingkan dengan arsitektur U-Net standar.

Di samping modifikasi arsitektur, kualitas citra input juga menjadi aspek fundamental menurut Saifullah dkk [2] mengevaluasi pengaruh teknik prapemrosesan citra diimplementasikan pendekatan hibrida *Contrast-Limited Adaptive Histogram Equalization* dan *Histogram Equalization* pada arsitektur *CNN U-Net*. Studi ini membuktikan bahwa peningkatan kontras citra melalui metode *CLAHE-HE* secara signifikan mempertegas delineasi batas tumor, yang berdampak pada peningkatan metrik akurasi hingga 0,9982 dan Dice Score mencapai 0,9977 pada tahapan pengujian.

Berdasarkan tinjauan terhadap literatur di atas, tampak bahwa kombinasi antara teknik prapemrosesan dan mekanisme atensi pada arsitektur U-Net memiliki potensi besar yang layak dieksplorasi lebih lanjut. Oleh karena itu, penelitian ini bertujuan mengimplementasikan sinergi antara pendekatan prapemrosesan tersebut dengan arsitektur atensi guna menghasilkan segmentasi yang lebih presisi.

3. METODE PENELITIAN

3.1. Dataset


Penelitian ini menggunakan dataset publik Brain Tumor Dataset dari Science Data Bank. Dataset ini berisi 3064 citra T1-weighted contrast-enhanced Magnetic Resonance Imaging dari 233 pasien, mencakup tiga jenis tumor otak yaitu Glioma (1426), Meningioma (708), Pituitary tumor (930).

3.2. Perancangan Sistem

Alur kerja sistem yang diusulkan terdiri dari tahapan prapemrosesan, augmentasi, pelatihan model, dan evaluasi. Skema perancangan sistem secara keseluruhan dapat dilihat pada Gambar 4.

Berdasarkan Gambar 4, diawali dengan prapemrosesan citra di-resize menjadi ukuran 256 x 256 piksel untuk konsistensi input [1]. Selanjutnya, metode *CLAHE* diterapkan untuk meningkatkan kontras lokal dan memperjelas batas tumor [1], [7]. Normalisasi Z-Score juga diterapkan untuk menstandarisasi rentang intensitas piksel [9].

Dataset dibagi dengan perbandingan 80% untuk data pelatihan (training), 10% untuk data validasi (validation), dan 10% untuk data pengujian (testing).



Gambar 4. Skema Perancangan

3.3. Prapemrosesan

Pada tahap ini akan dilakukan prapemrosesan yang bertujuan untuk menyeragamkan karakteristik citra sebelum diproses jaringan saraf tiruan.

Pengubah ukuran (Resizing) dan Normalisasi yang akan mengubah ukuran seluruh citra asli menjadi dimensi tetap yaitu 256×256 piksel untuk menyeragamkan vektor input dan efisiensi komputasi, mengikuti pendekatan yang dilakukan pada studi sebelumnya [2]. Selanjutnya, diterapkan Normalisasi Intensitas dengan parameter mean 0.5 dan standard deviation 0.5. Proses ini mentransformasi distribusi nilai piksel ke dalam rentang $[-1, 1]$, yang bertujuan mempercepat konvergensi gradien selama proses pelatihan model.

Peningkatan kontras *CLAHE* yang diterapkan untuk mempertegas batas tumor yang sering kali memiliki kontras rendah. Citra dibagi menjadi blok-blok kecil berukuran 8×8 , dan histogram pada setiap blok diekualisasi dengan parameter clip limit sebesar 2.0. Teknik ini secara efektif membatasi amplifikasi noise pada area homogen, sehingga detail tepi tumor menjadi lebih tajam tanpa merusak informasi jaringan sehat di sekitarnya [2].

3.4. Arsitektur Model

Model yang diusulkan adalah modifikasi dari U-Net standar dengan integrasi *Squeeze-and-Excitation* (SE). Arsitektur ini terdiri dari jalur encoder untuk ekstraksi fitur dan jalur decoder untuk rekonstruksi spasial [11]. Modul SE disisipkan setelah setiap blok konvolusi ganda pada *encoder* dan *decoder*. Modul ini berfungsi melakukan kalibrasi ulang fitur dengan memberikan bobot atensi pada *channel* fitur yang paling relevan dan menekan *channel* yang kurang informatif [6], [12].

3.5. Implementasi dan Evaluasi

Model dilatih menggunakan parameter batch size 32 dan epoch 50. Evaluasi kualitas hasil segmentasi diukur menggunakan metrik kuantitatif *Dice Similarity Coefficient* (DSC) dan *Intersection over Union* (IoU). DSC mengukur tumpang tindih antara prediksi dan *ground truth*, sedangkan IoU memberikan penalti lebih ketat pada kesalahan prediksi [6].


$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (6)$$

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (7)$$

4. HASIL DAN PEMBAHASAN

4.1. Evaluasi Kuantitatif

Kinerja model *Squeeze-and-Excitation U-Net* (SE U-Net) yang dilatih menggunakan citra hasil prapemrosesan CLAHE dievaluasi selama 50 epoch. Stabilitas dan kemampuan belajar model dipantau melalui pergerakan metrik *Dice Similarity Coefficient* (DSC) dan *Intersection over Union* (IoU) pada data latih (training) dan data validasi (validation), sebagaimana divisualisasikan pada Gambar 5.




Gambar 5. Grafik IoU, dan Dice Score

Berdasarkan Gambar 5, ada peningkatan performa yang tajam pada *epoch* 0 sampai 10 yang ditandai dengan lonjakan metrik yang signifikan. Grafik mulai stabil setelah *epoch* 10 sampai 40 dengan selisih kurva training dan validasi yang sempit, yang menandakan model belajar optimal. Memasuki fase stabilisasi pada *epoch* 40 sampai 50 yang mencapai hasil yang optimal, dengan data validasi model sudah mencapai rata-rata *Dice Score* sebesar 0.82 dan IoU sebesar 0.70.

4.2. Evaluasi Kualitatif

Validasi visual dilakukan dengan membandingkan prediksi model terhadap *ground truth* pada citra uji yang telah diproses dengan CLAHE.



Gambar 6. Visualisasi Hasil (a) Input + CLAHE, (b) Ground Truth, (c) Prediksi

Berdasarkan Gambar 6 memperlihatkan secara visual, penerapan metode CLAHE pada kolom input terbukti krusial dalam meningkatkan kontras lokal, membuat area tumor yang hiperintens terlihat jauh lebih menonjol dibandingkan jaringan otak sehat di sekitarnya, serta mempertegas tepi tumor yang semula kabur. Efektivitas ini didukung oleh hasil prediksi model SE U-Net yang mampu menghasilkan masker segmentasi yang sangat mendekati *Ground Truth*, di mana model berhasil menangkap morfologi tumor yang tidak beraturan dengan kontur yang halus. Selain itu, hasil prediksi tampak bersih tanpa adanya noise signifikan atau deteksi palsu (*false positive*) di area non-tumor, membuktikan bahwa model mampu membedakan *Region of Interest* (ROI) dengan latar belakang secara akurat.

4.3. Pembahasan

Hasil penelitian mengonfirmasi bahwa integrasi prapemrosesan CLAHE dan arsitektur SE U-Net secara signifikan meningkatkan akurasi segmentasi tumor otak. Prapemrosesan CLAHE terbukti krusial dalam mempertegas tepi tumor pada citra MRI yang memiliki variabilitas intensitas tinggi [2], sementara mekanisme *Squeeze-and-Excitation* (SE) menyempurnakannya dengan secara adaptif memfokuskan atensi model pada fitur tumor yang relevan sekaligus menekan noise latar belakang [1]. Sinergi antara perbaikan kualitas input dan selektivitas fitur ini menghasilkan kinerja yang kompetitif dengan capaian DSC 0.82 dan IoU 0.70, membuktikan efektivitas metode usulan dalam menangani kompleksitas segmentasi medis.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan model segmentasi tumor otak menggunakan arsitektur *Squeeze-and-Excitation U-Net* (SE U-Net) yang disinergikan dengan prapemrosesan *Contrast-Limited Adaptive Histogram Equalization* (CLAHE), di mana integrasi ini terbukti efektif memperbaiki kontras citra MRI dan meningkatkan fokus model pada fitur tumor. Hasil pengujian menunjukkan bahwa model mencapai kinerja yang andal dengan nilai *Dice Similarity Coefficient* (DSC) sebesar 0.82 dan *Intersection over Union* (IoU) sebesar 0.70 pada data validasi,

membuktikan bahwa pendekatan hibrida ini mampu menghasilkan segmentasi medis otomatis yang akurat dan konsisten. Berdasarkan temuan tersebut, penelitian selanjutnya disarankan untuk mengembangkan model ke dalam arsitektur 3D U-Net guna memanfaatkan informasi volumetrik antar-slice, menguji ketangguhan model pada dataset multi-kelas yang lebih kompleks seperti BraTS, serta mengeksplorasi teknik ensemble dengan metode deep learning lainnya untuk meningkatkan akurasi prediksi lebih lanjut.

DAFTAR PUSTAKA

- [1] Q. Abbas et al., "W-Attention-Residual U-Net Architecture for Massive Brain Tumor Segmentation," IEEE Access, 2024/2025.
- [2] D. Alhajim, K. Ansari-Asl, G. Akbarizadeh, dan M. N. Soorki, "Improved lung nodule segmentation with a squeeze excitation dilated attention based residual UNet," Scientific Reports, vol. 15, no. 1, p. 3770, 2025.
- [3] T. A. Dawood, A. T. Hashim, dan A. R. Nasser, "Advances in Brain Tumor Segmentation and Skull Stripping: A 3D Residual Attention U-Net Approach," Traitement du Signal, vol. 40, no. 5, pp. 1895–1908, 2023.
- [4] S. Gajula dan V. Rajesh, "Performance Analysis of Classification and Detection of Brain Tumor MRI Images Using Resnet50 Deep Residual U-Net," Journal of Iranian Medical Council, vol. 6, no. 1, pp. 101–110, 2023.
- [5] S. Jiang, X. Chen, dan C. Yi, "SSA-UNet: Whole brain segmentation by U-Net with squeeze-and-excitation block and self-attention block from the 2.5D slice image," IET Image Processing, vol. 18, no. 6, pp. 1566–1579, 2024.
- [6] W.-W. Lin, J.-W. Lin, T.-M. Huang, T. Li, M.-H. Yueh, dan S.-T. Yau, "A novel 2-phase residual U-net algorithm combined with optimal mass transportation for 3D brain tumor detection and segmentation," Scientific Reports, vol. 12, no. 1, p. 6452, 2022.
- [7] Y. Lyu dan X. Tian, "MWG-UNet++: Hybrid Transformer U-Net Model for Brain Tumor Segmentation in MRI Scans," Bioengineering, vol. 12, no. 2, p. 140, 2025.
- [8] N. Z. Naqvi dan K. R. Seeja, "An Attention-Based Residual U-Net for Tumour Segmentation Using Multi-Modal MRI Brain Images," IEEE Access, vol. 13, pp. 10240–10251, 2025.
- [9] R. Poonguzhali, S. Ahmad, P. T. Sivasankar, S. A. Babu, P. Joshi, G. P. Joshi, dan S. W. Kim, "Automated Brain Tumor Diagnosis Using Deep Residual U-Net Segmentation Model," Computers, Materials & Continua, vol. 74, no. 1, pp. 2179–2194, 2023.
- [10] G. Prasanna, J. R. Ernest, G. Lalitha, dan S. Narayanan, "Squeeze Excitation Embedded Attention UNet for Brain Tumor Segmentation," in International Conference on Emerging Electronics and Automation (ECCE), Springer, 2022, pp. 107–117.
- [11] S. Saifullah, A. P. Suryotomo, R. Dreżewski, R. Tanone, dan T. Tundo, "Optimizing Brain Tumor Segmentation Through CNN U-Net with CLAHE-HE Image Enhancement," in Proceedings of the 3rd International Conference on Smart Computing and Cyber Security (SmartCyber 2023), Atlantis Press, 2024, pp. 627–637.
- [12] J. Tie, H. Peng, dan J. Zhou, "MRI Brain Tumor Segmentation Using 3D U-Net with Dense Encoder Blocks and Residual Decoder Blocks," Computer Modeling in Engineering & Sciences, vol. 128, no. 2, pp. 427–446, 2021.
- [13] S. Vijay, T. Guhan, K. Srinivasan, P. M. D. R. Vincent, dan C.-Y. Chang, "MRI brain tumor segmentation using residual Spatial Pyramid Pooling-powered 3D U-Net," Frontiers in Public Health, vol. 11, p. 1091850, 2023.
- [14] J. Zhang, X. Lv, H. Zhang, dan B. Liu, "AResU-Net: Attention Residual U-Net for Brain Tumor Segmentation," Symmetry, vol. 12, no. 5, p. 721, 2020.
- [15] J. Zhang et al., "Attention Gate ResU-Net for Automatic MRI Brain Tumor Segmentation," IEEE Access, 2020.
- [16] L. Zhang, Y. Li, Y. Liang, C. Xu, T. Liu, dan J. Sun, "Dilated multi-scale residual attention (DMRA) U-Net: three-dimensional (3D) dilated multi-scale residual attention U-Net for brain tumor segmentation," Quantitative Imaging in Medicine and Surgery, vol. 14, no. 10, pp. 7249–7264, 2024.