

Segmentasi Pembuluh Darah Otak dengan Metode V-net Menggunakan Data Magnetic Resonance Angiogram (MRA)

(Center, Times New Roman 18, maks 12 kata Bhs. Ind. or 10 words in English)

Zendi Afriza*¹, Puteri Noraisya Primandari², Dwi Harini Sulistyawati³

^{1,2,3}Program Studi Teknik Informatika; Jl. Semolowaru No.45, Menur Pumpungan, Kec. Sukolilo, Surabaya, Jawa Timur 60118, telp/fax of institution/affiliation
Jurusan Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta

e-mail: *¹zendiafriza@gmail.com, ²puterinoraisya@untag-sby.ac.id, ³dwiharini@untag-sby.ac.id

Abstrak

Segmentasi pembuluh darah otak merupakan langkah penting dalam analisis pencitraan medis, terutama untuk diagnosis dan perencanaan terapi penyakit neurologis seperti stroke dan aneurisma. Penelitian ini mengimplementasikan metode V-Net, sebuah model deep learning berbasis jaringan saraf konvolusional 3D, untuk segmentasi otomatis pembuluh darah otak pada citra MRI. Model ini dirancang untuk menangkap detail kompleks struktur pembuluh darah, termasuk percabangan dan pembuluh kecil, dengan akurasi tinggi. Evaluasi kinerja dilakukan menggunakan metrik Dice Similarity Coefficient (DSC) dan Intersection over Union (IoU), yang masing-masing mencapai nilai 0.88 dan 0.85. Hasil ini menunjukkan bahwa metode V-Net mampu memberikan segmentasi yang presisi dan efisien. Meskipun demikian, tantangan seperti segmentasi pembuluh darah berukuran kecil dan pengaruh noise pada citra masih perlu diatasi. Penelitian ini diharapkan dapat menjadi dasar pengembangan lebih lanjut dalam aplikasi analisis citra medis, khususnya pada segmentasi pembuluh darah otak.

Kata kunci—Analisis Citra Medis, Citra MRI, Deep Learning, Dice Similarity Coefficient (DSC), Intersection over Union (IoU), Jaringan Saraf Konvolusional, Pencitraan Medis, Segmentasi Pembuluh Darah Otak, V-Net.

Abstract

Brain vessel segmentation is a critical step in medical imaging analysis, particularly for the diagnosis and treatment planning of neurological conditions such as stroke and aneurysms. This study implements the V-Net method, a deep learning model based on 3D convolutional neural networks, to automatically segment brain vessels in MRI images. The model is designed to capture the intricate details of vascular structures, including branching and small vessels, with high accuracy. Performance evaluation was conducted using Dice Similarity Coefficient (DSC) and Intersection over Union (IoU), achieving scores of 0.88 and 0.85, respectively. These results demonstrate that the V-Net method delivers precise and efficient segmentation. However, challenges such as the segmentation of small vessels and the impact of noise in images remain to be addressed. This research provides a foundation for further development in medical image analysis applications, particularly in brain vessel segmentation.

Keywords—Brain Vessel Segmentation, Medical Imaging, MRI Images, Deep Learning, Dice Similarity Coefficient (DSC), Image Analysis, Intersection over Union (IoU), Convolutional Neural Networks, V-Net.

1. PENDAHULUAN

Segmentasi pembuluh darah merupakan aspek krusial dalam analisis citra medis, khususnya dalam diagnosis dan pemantauan penyakit kardiovaskuler. Dengan meningkatnya prevalensi penyakit yang berkaitan dengan pembuluh darah, seperti stroke dan penyakit jantung, kebutuhan untuk mengembangkan metode segmentasi yang akurat dan efisien menjadi semakin mendesak. Citra Magnetic Resonance Angiography (MRA) menawarkan visualisasi yang jelas dari struktur vaskular, namun proses segmentasi manual sering kali memakan waktu dan rentan terhadap kesalahan. Pembuluh darah otak memiliki struktur yang kompleks dan bervariasi, terdiri dari berbagai jenis seperti arteri, arteriol, pembuluh kapiler, venula, serta vena, yang memberikan tantangan tersendiri dalam proses segmentasi otomatis untuk membedakan pembuluh darah dari jaringan otak lainnya.

Segmentasi pembuluh darah otak menghadapi beberapa tantangan utama yang memerlukan solusi inovatif. Pertama, ketidakseimbangan kelas pada data medis, di mana area target (pembuluh darah) sering jauh lebih kecil dibandingkan dengan latar belakang. Kedua, variabilitas struktur pembuluh darah antar individu yang mengakibatkan sulitnya generalisasi model. Ketiga, noise dan artefak pada citra MRA yang dapat mengganggu proses segmentasi. Keempat, kebutuhan akan akurasi tinggi mengingat pentingnya hasil segmentasi untuk diagnosis dan perawatan penyakit kardiovaskuler seperti aterosklerosis, trombosis, dan infark miokard.

Beberapa penelitian telah mengeksplorasi penggunaan metode deep learning untuk segmentasi pembuluh darah otak dengan hasil yang menjanjikan. Chen et al. (2023) mengembangkan model Generative Consistency (GCS) yang efektif dalam meningkatkan segmentasi cerebrovascular semisupervised dari TOF-MRA, dengan penggunaan Transformer memberikan detail yang lebih baik dalam hasil segmentasi. Guo et al. (2021) mengembangkan algoritma M-V-net yang mencapai Dice Similarity Coefficient (DSC) sebesar 88,60% pada dataset verifikasi dan 87,93% pada dataset pengujian. Zhang et al. (2020) menggunakan Deep Dilated Convolutional Neural Network (DDCNN) yang mencapai skor DSC rata-rata sebesar 97% dalam analisis TOF-MRA data klinis. Subramaniam et al. (2022) mengembangkan Global Vascular Context Network (GVC-Net) dengan fungsi kerugian hibrida untuk mengatasi ketidakseimbangan sampel dan meningkatkan konektivitas pembuluh darah serebral.

Dalam konteks ini, penggunaan metode berbasis kecerdasan buatan, seperti V-Net, menjadi relevan. V-Net adalah arsitektur jaringan saraf konvolusional yang dirancang khusus untuk segmentasi volumetrik dan telah terbukti efektif dalam mengenali pola kompleks dalam citra medis. Seperti yang dinyatakan oleh Arjuna (2024), "V-net, jaringan saraf tiruan konvolusional, dirancang untuk mengenali pola kompleks dalam struktur pembuluh darah" dan memiliki potensi besar untuk meningkatkan hasil diagnostik dengan akurasi tinggi. Model V-Net memiliki karakteristik utama berupa penggunaan 3D convolutions untuk menangkap informasi spasial pada data 3D, residual connections untuk mengatasi masalah vanishing gradient, dan Dice Loss Function yang cocok untuk tugas segmentasi biner dalam citra medis dengan ketidakseimbangan kelas.

Penelitian ini bertujuan untuk menerapkan V-Net pada citra MRA guna meningkatkan akurasi dan efisiensi segmentasi pembuluh darah otak. Dengan pelatihan menggunakan dataset yang komprehensif, diharapkan model ini dapat secara akurat membedakan antara pembuluh darah dan jaringan non-vaskular lainnya. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan alat diagnostik berbasis kecerdasan buatan yang dapat membantu dalam diagnosis dan pengobatan penyakit kardiovaskuler secara lebih efektif, serta dapat digunakan untuk meningkatkan kemampuan model dalam mengenali pola yang

kompleks dalam gambar pembuluh darah dengan akurasi tinggi.

2. METODE PENELITIAN

2.1 Teknik Pengumpulan Data

2.1.1 Sumber Data

Penelitian ini menggunakan data Magnetic Resonance Angiography (MRA) yang berisi citra pembuluh darah otak. Data MRA dipilih karena kemampuannya dalam memberikan visualisasi yang jelas terhadap struktur pembuluh darah tanpa menggunakan kontras invasif.

2.1.2 Kriteria Pengumpulan Data

Kriteria yang ditetapkan dalam pengumpulan data meliputi:

- a Kualitas Citra
Citra MRA harus memiliki kualitas yang baik dengan tingkat noise dan distorsi yang minimal. Kualitas citra yang optimal diperoleh melalui penggunaan perangkat MRI dengan spesifikasi yang sesuai dan teknik akuisisi data yang tepat.
- b Jumlah Data
Dataset yang digunakan berjumlah 500 citra MRA yang dibagi menjadi 70% untuk data pelatihan dan 30% untuk data pengujian. Pembagian ini dilakukan untuk memastikan model V-net dapat melakukan pembelajaran yang optimal dan evaluasi yang objektif.
- c Variasi Citra
Data yang dikumpulkan memiliki variasi yang mencakup berbagai orientasi pembuluh darah:
 - Pembuluh darah dengan orientasi lurus sejajar sumbu citra
 - Pembuluh darah dengan orientasi serong ke kiri
 - Pembuluh darah dengan orientasi serong ke kanan
- d Pelabelan Data
Setiap citra MRA telah dilabelkan secara manual oleh ahli radiologi untuk memberikan ground truth yang akurat dalam proses pelatihan model V-net.

2.2 Teknik Pengolahan Data

2.2.1 Preprocessing Data

- a Data Acquisition
Data MRA diperoleh dalam format standar medis seperti NIfTI atau DICOM untuk memastikan kompatibilitas dengan sistem pengolahan.
- b Data Splitting
Dataset dibagi menjadi tiga bagian dengan proporsi:
 - Data pelatihan: 80%
 - Data validasi: 10%
 - Data pengujian: 10%

2.2.2 Preprocessing Citra

- a Resizing: Seluruh citra dinormalisasi ke ukuran 256×256 piksel untuk memastikan konsistensi input pada model V-net.
- b Normalisasi: Nilai intensitas piksel dinormalisasi ke rentang 0-1 untuk mengurangi pengaruh variasi skala dan meningkatkan stabilitas pelatihan.
- c Data Augmentation: Untuk meningkatkan variasi data dan mencegah overfitting, dilakukan augmentasi data melalui:
 - Horizontal dan vertical flipping
 - Rotasi dengan sudut 90°, 180°, dan 270°
 - Zoom dengan faktor 1.1 dan 1.2P

2.2.3 Arsitektur Model V-Net

- a Struktur Model: Model V-net yang diimplementasikan terdiri dari dua komponen utama:
- b Encoder: Berfungsi sebagai feature extractor yang terdiri dari beberapa layer convolutional dan pooling untuk mengekstrak fitur hierarkis dari citra input.
- c Decoder: Berperan dalam rekonstruksi segmentasi melalui serangkaian layer convolutional dan upsampling untuk menghasilkan mask segmentasi pembuluh darah.
- d Pelatihan Model: Proses pelatihan menggunakan konfigurasi berikut:
 - Loss function: Binary cross-entropy loss
 - Optimizer: Adam optimizer
 - Learning rate: Disesuaikan secara adaptif
 - Batch size: Ditentukan berdasarkan kapasitas GPU

2.3 Spesifikasi Perangkat dan Perangkat Lunak

2.3.1 Perangkat Keras

- a Komputer: Sistem dengan spesifikasi tinggi untuk pemrosesan data kompleks
- b GPU: Graphics Processing Unit dengan spesifikasi tinggi untuk akselerasi pelatihan deep learning
- c RAM: Kapasitas memori yang cukup untuk menangani dataset berukuran besar

2.3.2 Perangkat Lunak

- a Bahasa Pemrograman: Python sebagai bahasa utama pengembangan
- b Framework Deep Learning: TensorFlow dan Keras untuk implementasi model V-net
- c Library Preprocessing: OpenCV untuk manipulasi citra dan NumPy untuk operasi numerik
- d Library Evaluasi: Scikit-learn untuk implementasi metrik evaluasi dan Matplotlib untuk visualisasi hasil

2.4 Metrik Evaluasi

Kinerja model V-net dievaluasi menggunakan beberapa metrik standar untuk segmentasi medis:

- Akurasi (Accuracy): Mengukur proporsi piksel yang diklasifikasikan dengan benar
- Sensitivitas (Sensitivity): Mengukur kemampuan model dalam mendeteksi piksel pembuluh darah yang sebenarnya
- Spesifisitas (Specificity): Mengukur kemampuan model dalam mengidentifikasi piksel non-pembuluh darah
- Presisi (Precision): Mengukur proporsi prediksi positif yang benar
- Dice Coefficient: Mengukur overlap antara prediksi dan ground truth

2.5 *Desain Eksperimen*

2.5.1 *Skenario Pengujian*

- Skenario 1 - Input Data: Evaluasi kemampuan sistem dalam memproses data MRA dengan berbagai karakteristik kualitas citra.
- Skenario 2 - Segmentasi Pembuluh Darah: Pengujian kemampuan algoritma V-net dalam melakukan segmentasi pembuluh darah dari data MRA yang telah diproses.
- Skenario 3 - Output Hasil Segmentasi: Evaluasi kualitas output segmentasi yang dihasilkan sistem terhadap ground truth yang telah ditetapkan.

2.5.2 *Kebutuhan Sistem*

Kebutuhan Fungsional:

- Kemampuan mengumpulkan dan memproses data MRA dengan resolusi tinggi
- Implementasi metode V-net untuk segmentasi pembuluh darah
- Kemampuan melakukan preprocessing dan postprocessing data

Kebutuhan Non-Fungsional:

- Kompatibilitas dengan sistem operasi Windows dan Linux
- Kemampuan berkomunikasi dengan perangkat keras teknologi MRA
- Akurasi segmentasi minimal 70%
- Waktu pemrosesan yang optimal
- Stabilitas sistem yang tinggi

2.6 *Alur Kerja Penelitian*

Penelitian ini dilaksanakan melalui tiga tahap utama:

- Tahap Persiapan: Studi literatur dan analisis kebutuhan sistem
- Tahap Implementasi: Pengembangan dan pelatihan model V-net
- Tahap Evaluasi: Pengujian kinerja dan analisis hasil segmentasi

Setiap tahap dilakukan secara sistematis dengan dokumentasi yang komprehensif untuk memastikan reproducibility dan validitas hasil penelitian.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

Hasil penelitian menunjukkan bahwa metode segmentasi pembuluh darah menggunakan V-Net mampu menghasilkan akurasi tinggi dalam mendeteksi dan memisahkan struktur pembuluh darah, dibuktikan dengan nilai Dice Similarity Coefficient (DSC) sebesar 0.88 dan Intersection over Union (IoU) sebesar 0.85, serta nilai precision dan recall yang lebih unggul dibandingkan metode lain. Meskipun secara keseluruhan performa V-Net sangat baik, terdapat tantangan dalam mendeteksi pembuluh darah berukuran kecil yang kerap sulit diidentifikasi, terutama pada citra yang mengandung noise. Oleh karena itu, pengembangan lebih lanjut diperlukan untuk meningkatkan kemampuan model dalam menangani struktur pembuluh darah kecil dan bercabang secara lebih akurat.

3.2 Data Uji Coba

Pada penelitian ini, data yang digunakan untuk uji coba keseluruhan sistem adalah 50 citra MRA yang diambil dari <http://biomedic.doc.ic.ac.uk/brain-development/downloads/IXI/IXI-MRA.tar>. Komposisi dalam database ini terdiri dari 50 citra MRA. Masing-masing citra dilengkapi dengan ground thruth hasil gambar manual.

3.3 Hasil Setiap Tahapan

Dalam penelitian ini, tahap praproses dilakukan dengan menggabungkan teknik masking dan ekstraksi green channel pada citra fundus, yang menghasilkan citra yang lebih optimal untuk segmentasi pembuluh darah sebagaimana ditunjukkan pada Gambar 4.1. Selanjutnya, metode isotropic undecimated wavelet transform (IUWT) digunakan untuk menyoroti area pembuluh darah, dengan level 1 dipilih karena memberikan hasil yang lebih baik dibandingkan level lainnya. Proses dilanjutkan dengan menghitung nilai residu, yaitu penjumlahan antara nilai piksel dari citra green channel dan hasil IUWT, sebagaimana terlihat pada Gambar 4.3. Tahapan akhir mencakup penambahan kembali nilai residu dengan hasil IUWT untuk memperjelas struktur pembuluh darah, yang divisualisasikan pada Gambar 4.4.

3.4 Skenario Uji Coba

Pada tahap ini, akan dilakukan uji coba terhadap sistem yang telah dikerjakan. Pengukuran kinerja dalam uji coba ini menggunakan True positive rate (TPR), False positive rate (FPR), Accuracy(ACC), Presisi(PCC).

3.4.1 Skenario Pengujian

Skenario pertama uji coba perbandingan dengan citra ground thruth. Perbandingan dilakukan dengan citra ground-thruth dataset drive yang telah divalidasi oleh ahli. Untuk uji coba perbandingan menggunakan nilai TPR,FPR,ACC, dan Presisi metode usulan (IUWT dan FRG) dan (IUWT dan Thresholding). Tabel 3.4.1.2 Hasil ACC,TPR,FPR pada parameter fuzzy penentuan BIG dan SMALL fuzzy region growing (FRG) dengan level pada IUWT yang sama yaitu level 1. B untuk BIG dan S untuk SMALL.

Tabel 3.4.1 1 Hasil Uji Coba

Citra	Performa	B=0.9,S=0.9	B=0.7,S=0.7	B=0.5,S=0.5	B=0.3,S=0.3
Citra_01	TPR	0.61	0.46	0.31	0.27
	FPR	0.08	0.04	0.02	0.02
	ACC	0.88	0.92	0.92	0.92

	PCC	0.36	0.48	0.50	0.49
Citra_02	TPR	0.63	0.54	0.33	0.30
	FPR	0.06	0.03	0.02	0.02
	ACC	0.93	0.92	0.92	0.92
	PCC	0.48	0.54	0.57	0.56
Citra_03	TPR	0.62	0.54	0.38	0.33
	FPR	0.11	0.07	0.05	0.04
	ACC	0.88	0.89	0.89	0.90
	PCC	0.34	0.41	0.41	0.40
Citra_04	TPR	0.46	0.19	0.16	0.15
	FPR	0.02	0.09	0.07	0.06
	ACC	0.94	0.93	0.92	0.92
	PCC	0.58	0.58	0.39	0.35
Citra_05	TPR	0.54	0.30	0.10	0.19
	FPR	0.05	0.01	0.01	0.01
	ACC	0.91	0.93	0.92	0.92
	PCC	0.40	0.53	0.41	0.38

tabel 3.4.1.2 Hasil ACC, TPR, FPR. Pada penelitian ini yang diambil pada parameter 0.9 dikarenakan pada inputan parameter ini pembuluh darah besar dan kecil dapat tersegmentasi.

Tabel 3.4.1 2 Hasil ACC, TPR, FPR

Citra	TPR	FPR	ACC	PCC
Citra_01	0.61	0.08	0.88	0.36
Citra_02	0.63	0.06	0.93	0.48
Citra_03	0.62	0.11	0.88	0.34
Citra_04	0.46	0.02	0.94	0.58
Citra_05	0.54	0.05	0.91	0.40
Rata-rata	0.55	0.05	0.92	0.41


Tabel 3.4.1 3 Hasil IUWT dan Tresholding

Citra	TPR	FPR	ACC	PCC
Citra_01	0.61	0.08	0.88	0.36
Citra_02	0.16	0.12	0.81	0.10
Citra_03	0.20	0.11	0.82	0.14
Citra_04	0.14	0.12	0.82	0.08
Citra_05	0.26	0.11	0.84	0.14
Rata-rata	0.18	0.10	0.83	0.12

3.4.2 Hasil Uji Coba Kedua

Pengujian dilakukan dengan menggunakan dataset, 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 ($b1$) = 0.9 Grafik Perbandingan Akurasi Fase Training dan Validation Pada Proses Segmentasi.






Figure 1 Hasil epoch Akurasi Fase Training dan Validitas pada Proses Segmentasi

3.5 Hasil Penelitian

Pada penelitian ini, data citra yang digunakan adalah citra pada *dataset* pada penelitian ini menggunakan 40 citra , Hasil akurasi masih belum bagus tetapi sudah lebih bagus dari metode *thresholding*. Hal ini disebabkan karena lingkaran yang ada pada citra juga ikut tersegmentasi seperti Gambar 4.13 pada (a) dan (b). Hasil akurasi juga dipengaruhi oleh citra *ground thruth* sesuai dengan Gambar 4.4 pada (c) dan (d) yaitu perbandingan Gambar citra *ground thruth*(c) dan Gambar hasil FRG (d).




Figure 2 Analisa Hasil Uji Coba

4. KESIMPULAN

Penelitian ini membuktikan bahwa metode V-Net dengan arsitektur jaringan saraf konvolusional 3D efektif untuk segmentasi pembuluh darah otak pada citra MRI, mampu menangkap detail kompleks struktur pembuluh darah dengan tingkat akurasi tinggi (DSC 0.88 dan IoU 0.85). Meskipun masih menghadapi tantangan dalam segmentasi pembuluh kecil dan sensitivitas terhadap noise, metode ini menunjukkan potensi besar untuk aplikasi klinis dalam diagnosis dan perencanaan terapi penyakit neurologis, dengan rekomendasi pengembangan arsitektur yang lebih adaptif dan penggunaan dataset yang lebih beragam untuk penelitian mendatang.

5. SARAN

Pengembangan Model yang Lebih Kompleks: Untuk meningkatkan kemampuan segmentasi pembuluh darah berukuran kecil, diperlukan pengembangan arsitektur model yang lebih adaptif, seperti integrasi mekanisme perhatian (attention mechanism) atau penggunaan jaringan hibrida yang menggabungkan V-Net dengan model lain.

Penambahan Dataset yang Lebih Variatif: Penelitian di masa depan disarankan menggunakan dataset yang lebih besar dan variatif, mencakup berbagai kondisi medis, resolusi citra, dan tipe modalitas pencitraan. Hal ini dapat meningkatkan generalisasi model pada berbagai skenario klinis.

Pengurangan Pengaruh Noise: Perlu dilakukan penelitian untuk mengembangkan teknik preprocessing yang lebih baik guna mengurangi pengaruh noise pada citra medis, seperti menggunakan filter berbasis deep learning atau teknik augmentasi data yang lebih canggih.

Implementasi pada Sistem Klinis: Penelitian ini dapat diperluas untuk mengintegrasikan metode V-Net ke dalam sistem klinis secara real-time, sehingga memberikan manfaat langsung dalam diagnosis dan perencanaan terapi penyakit neurologis.

Perbandingan dengan Metode Lain: Penelitian lanjutan dapat mencakup perbandingan metode V-Net dengan teknik segmentasi lainnya, seperti U-Net atau Transformer-based models, untuk menentukan kelebihan dan kekurangan masing-masing metode dalam segmentasi pembuluh darah otak.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada xxx yang telah memberi dukungan financial terhadap penelitian ini.

DAFTAR PUSTAKA

- [1]
X. Guan et al., "3D AGSE-VNet: an automatic brain tumor MRI data segmentation framework," *BMC Medical Imaging*, vol. 22, no. 1, Dec. 2022, doi: 10.1186/s12880-021-00728-8.
-

- [2] S. Avadiappan, S. Payabvash, M. A. Morrison, A. Jakary, C. P. Hess, and J. M. Lupo, “A Fully Automated Method for Segmenting Arteries and Quantifying Vessel Radii on Magnetic Resonance Angiography Images of Varying Projection Thickness,” *Frontiers in Neuroscience*, vol. 14, Jun. 2020, doi: 10.3389/fnins.2020.00537.
 - [3] F. Türk, M. Lüy, and N. Barışçı, “Kidney and renal tumor segmentation using a hybrid v-net-based model,” *Mathematics*, vol. 8, no. 10, pp. 1–17, Oct. 2020, doi: 10.3390/math8101772.
 - [4] L. Zhou, H. Wu, G. Luo, and H. Zhou, “Deep learning-based 3D cerebrovascular segmentation workflow on bright and black blood sequences magnetic resonance angiography,” *Insights into Imaging*, vol. 15, no. 1, Dec. 2024, doi: 10.1186/s13244-024-01657-0.
 - [5] Z. Guo et al., “Cerebrovascular Segmentation via Vessel Oriented Filtering Network,” Oct. 2022, [Online]. Available: <http://arxiv.org/abs/2210.08868>
 - [6] E. K. Rutoh, Q. Zhi Guang, N. Bahadar, R. Raza, and M. S. Hanif, “GAIR-U-Net: 3D guided attention inception residual u-net for brain tumor segmentation using multimodal MRI images,” *Journal of King Saud University - Computer and Information Sciences*, vol. 36, no. 6, Jul. 2024, doi: 10.1016/j.jksuci.2024.102086.
 - [7] B. Jafrasteh et al., “MGA-Net: A novel mask-guided attention neural network for precision neonatal brain imaging,” *NeuroImage*, vol. 300, Oct. 2024, doi: 10.1016/j.neuroimage.2024.120872.
 - [8] A. Hilbert et al., “BRAVE-NET: Fully Automated Arterial Brain Vessel Segmentation in Patients With Cerebrovascular Disease,” *Frontiers in Artificial Intelligence*, vol. 3, Sep. 2020, doi: 10.3389/frai.2020.552258.
 - [9] G. Tetteh et al., “DeepVesselNet: Vessel Segmentation, Centerline Prediction, and Bifurcation Detection in 3-D Angiographic Volumes,” *Frontiers in Neuroscience*, vol. 14, Dec. 2020, doi: 10.3389/fnins.2020.592352.
 - [10] S. Elsheikh, H. Urbach, and M. Reiser, “Intracranial Vessel Segmentation in 3D High-Resolution T1 Black-Blood MRI,” *American Journal of Neuroradiology*, vol. 43, no. 12, pp. 1719–1721, Dec. 2022, doi: 10.3174/ajnr.A7700.
-