

Attention U-Net untuk Segmentasi Perdarahan Otak Multi-Kelas pada Dataset CT Kepala

Afu Ichsan Pradana^{*1}, Harsanto², Dwi Hartanti³

¹²³Universitas Duta Bangsa Surakarta

¹²³Surakarta

Email: ¹afu_ichsan@udb.ac.id, ²harsanto@udb.ac.id, ³dwhartanti@udb.ac.id

Abstract

Brain hemorrhage is a life threatening condition that requires rapid and accurate assessment of hematoma location and volume on head CT images. Manual delineation by radiologists is time-consuming and prone to inter observer variability, so automated segmentation methods are needed. This study investigates an Attention U-Net model for automatic brain hemorrhage segmentation on CT images. The dataset, obtained from Roboflow in COCO segmentation format, was converted into pixel-wise binary masks and divided into training, validation, and test sets. Pre-processing included resizing, normalization, and data augmentation to improve generalization. The Attention U-Net was trained using the Adam optimizer with a learning rate of 1×10^{-4} for 20 epochs, employing a combined Binary Cross Entropy and Dice loss. Quantitative evaluation on the test set yielded a test loss of 0.1935 and a Dice coefficient of 0.6696. These results indicate that Attention U-Net is a promising approach for assisting brain hemorrhage assessment and can be further improved with larger and more diverse datasets.

Keywords: Attention U-Net; brain hemorrhage; CT scan; deep learning; medical image segmentation.

Abstraksi

Perdarahan otak merupakan kondisi yang mengancam jiwa dan memerlukan penilaian lokasi serta volume hematoma pada citra CT kepala secara cepat dan akurat. Delineasi manual oleh radiolog memerlukan waktu dan berpotensi menimbulkan variasi antar pengamat, sehingga dibutuhkan metode segmentasi otomatis. Penelitian ini mengkaji pemanfaatan model Attention U-Net untuk segmentasi otomatis perdarahan otak pada citra CT. Dataset diperoleh dari Roboflow dalam format segmentasi COCO, kemudian dikonversi menjadi mask biner piksel demi piksel dan dibagi menjadi data latih, validasi, dan uji. Tahap praproses meliputi resize, normalisasi, serta augmentasi untuk meningkatkan kemampuan generalisasi model. Attention U-Net dilatih menggunakan optimizer Adam dengan learning rate 1×10^{-4} selama 20 epoch, dengan fungsi loss gabungan Binary Cross Entropy dan Dice loss. Evaluasi kuantitatif pada data uji menghasilkan nilai test loss 0,1935 dan dice coefficient 0,6696. Hasil ini menunjukkan bahwa Attention U-Net merupakan pendekatan yang optimal untuk membantu penilaian perdarahan otak dan masih dapat ditingkatkan dengan dataset yang lebih besar dan beragam.

Kata Kunci: Attention U-Net, CT scan; Deep Learning, Perdarahan otak, Segmentasi citra medis

1. PENDAHULUAN

Perdarahan otak, khususnya perdarahan intraserebral hemorrhage, merupakan salah satu bentuk stroke yang paling mematikan dan menyumbang sekitar 10–15% dari seluruh kasus stroke di dunia[1]. Kondisi ini ditandai oleh terbentuknya hematoma di parenkim otak yang berkembang cepat dan sering menyebabkan defisit neurologis berat serta mortalitas tinggi. Faktor risiko seperti hipertensi kronis, usia lanjut, dan komorbid vaskular lain terbukti berkontribusi terhadap memburuknya prognosis pasien [1],[2]. Dalam konteks pelayanan kesehatan, penanganan cepat dan tepat terhadap perdarahan otak menjadi sangat krusial untuk menurunkan angka kematian dan kecacatan jangka panjang. Dalam praktik klinis sehari-hari, modalitas utama untuk deteksi dini perdarahan otak adalah *computed tomography* (CT) kepala non-kontras. Pemeriksaan CT mampu menampilkan lokasi, bentuk, dan volume hematoma dengan cepat, sehingga sangat penting dalam pengambilan keputusan terapi, seperti tindakan bedah maupun penatalaksanaan konservatif[2]. Sejumlah penelitian menunjukkan bahwa volume awal hematoma dan dinamika perluasan hematoma merupakan prediktor kuat mortalitas 30 hari dan luaran fungsional jangka panjang [3],[4]. Oleh karena itu, pengukuran volume perdarahan yang akurat dan efisien merupakan kebutuhan klinis yang mendesak, terutama di unit gawat darurat dan stroke unit yang menangani beban kasus tinggi.

Di Indonesia, urgensi masalah ini semakin menguat karena beban stroke nasional tergolong tinggi, dan layanan stroke di rumah sakit sering menangani kasus dengan kondisi akut yang memerlukan keputusan cepat. Beberapa laporan menunjukkan bahwa stroke masih menjadi penyebab kematian dan disabilitas utama di Indonesia, dengan tantangan pelayanan yang besar pada fase emergensi[5]. Selain itu, studi klinis di Indonesia juga menunjukkan kontribusi hipertensi berat yang dominan pada kejadian stroke hemoragik, sehingga risiko ICH pada populasi Indonesia menjadi isu yang relevan[6]. Masalah ini diperberat oleh keterbatasan jumlah dan distribusi radiolog yang belum merata masih jauh di bawah target nasional, sehingga pembacaan CT kepala di banyak rumah sakit daerah berpotensi terlambat [7].

Saat ini, segmentasi hematoma pada citra CT masih banyak dilakukan secara manual atau semiotomatis oleh ahli radiologi dan klinisi. Proses ini memerlukan waktu yang tidak sedikit, sangat bergantung pada pengalaman operator, serta rentan terhadap variasi antar pengamat, terutama pada lesi yang kecil, tidak beraturan, atau memiliki kontras rendah terhadap jaringan sekitarnya [2],[4]. Hal ini membuka peluang besar untuk memanfaatkan metode otomatis berbasis kecerdasan buatan guna membantu proses deteksi dan segmentasi perdarahan otak secara cepat dan konsisten[8]. Perkembangan deep learning, khususnya convolutional neural networks (CNN), telah merevolusi bidang analisis citra medis, termasuk tugas klasifikasi, deteksi, dan segmentasi struktur anatomi maupun lesi patologis. Salah satu arsitektur yang paling berpengaruh adalah U-Net, yang diperkenalkan sebagai jaringan *encoder–decoder* dengan skip connection simetris untuk segmentasi citra biomedis[9]. Berbagai penelitian kemudian mengadaptasi dan mengembangkan U-Net untuk segmentasi perdarahan intrakranial dan stroke hemoragik

pada citra CT, serta melaporkan peningkatan akurasi pengukuran volume dan delineasi lesi dibandingkan metode tradisional [8],[10],[11].

Salah satu perkembangan penting dalam keluarga U-Net adalah integrasi mekanisme perhatian (*attention*). Attention U-Net yang diperkenalkan oleh Oktay dkk. memasukkan attention gate pada skip connection untuk secara adaptif menonjolkan fitur yang relevan dan menekan area yang tidak berkaitan dengan struktur target [12]. Pendekatan ini terbukti dapat meningkatkan performa segmentasi berbagai organ dan lesi pada citra CT dan MRI tanpa menambah beban komputasi secara berlebihan[13]. Studi-studi terkini melaporkan bahwa arsitektur *attention-based* residual U-Net dan varian sejenis mampu memberikan segmentasi *multi-label* perdarahan otak dengan presisi yang lebih baik dibandingkan model baseline [13],[14],[15]. Hasil-hasil tersebut menegaskan potensi mekanisme attention untuk meningkatkan sensitivitas terhadap lesi kecil dan memperbaiki ketepatan delineasi batas perdarahan.

Penelitian ini berfokus pada pengembangan dan evaluasi model Attention U-Net untuk segmentasi perdarahan otak pada citra medis, khususnya citra CT kepala yang telah dianotasi pada level piksel. Tujuan utama penelitian adalah menghasilkan model segmentasi otomatis yang mampu mengidentifikasi dan mengukur area perdarahan secara akurat, sehingga dapat mendukung proses penegakan diagnosis dan penentuan strategi terapi klinis.

2. TINJAUAN PUSTAKA

Berbagai penelitian menunjukkan bahwa segmentasi otomatis mampu mempercepat dan menstandarkan pengukuran volume perdarahan, yang sebelumnya dilakukan secara manual dan sangat bergantung pada keahlian klinisi[16],[17]. Pendekatan awal banyak memanfaatkan arsitektur U-Net tiga dimensi maupun dua dimensi untuk segmentasi lesi stroke hemoragik dengan hasil yang menjanjikan pada berbagai dataset klinis [18],[19]. Namun, U-Net standar cenderung mengalami penurunan kinerja pada lesi berukuran kecil dan batas lesi yang kabur, sehingga memotivasi pengembangan varian arsitektur yang lebih kaya fitur [11], [20].

Beberapa studi mengusulkan modifikasi U-Net khusus untuk intracranial hemorrhage (ICH). Wang dan Wang memperkenalkan MSRL-Net, yang menambahkan residual dan multi-scale learning ke dalam kerangka U-Net untuk meningkatkan segmentasi lesi kecil pada CT kepala[11]. Piao dkk. mengusulkan TransHarDNet, yang menggabungkan blok HarDNet dan transformer di atas U-Net untuk meningkatkan efisiensi dan kecepatan segmentasi ICH[21]. Studi lain memanfaatkan mekanisme fokus dan attention gate untuk meningkatkan akurasi pengukuran volume perdarahan intraserebral melalui jaringan segmentasi yang dirancang khusus[17]. Hasil-hasil tersebut menegaskan bahwa penguatan jalur fitur dan desain skip connection menjadi kunci dalam meningkatkan performa segmentasi citra medis yang kompleks.

Tren terkini mengarah pada integrasi mekanisme attention secara eksplisit ke dalam arsitektur U-Net. GA-UNet, WRANet, dan berbagai attention-based U-Net lain menunjukkan bahwa attention pada level kanal dan spasial dapat membantu jaringan memusatkan perhatian pada area yang relevan, sekaligus menekan informasi latar belakang yang tidak penting [22]. Dalam konteks perdarahan otak, Prakasam dkk. mengembangkan Spatial Attention-based CSR-UNet untuk segmentasi subdural dan epidural hemorrhage, dan melaporkan peningkatan presisi segmentasi pada head CT[23], sementara Chang dkk. mengusulkan All Attention U-Net untuk segmentasi multi-jenis perdarahan intrakranial dan memperoleh peningkatan Dice yang signifikan dibandingkan baseline U-Net konvensional[13]. Lin dkk. selanjutnya memperluas pendekatan ini melalui Attention-based Residual U-Net untuk segmentasi multi-label berbagai tipe perdarahan otak, menunjukkan bahwa integrasi attention dan residual connection dapat meningkatkan generalisasi model pada variasi data klinis yang luas[14]. Secara keseluruhan, literatur terkini menunjukkan bahwa kombinasi U-Net dengan mekanisme attention merupakan arah yang menjanjikan untuk segmentasi perdarahan otak yang lebih akurat dan robust.

Meskipun beragam varian U-Net dan attention-based U-Net telah dilaporkan efektif, masih terdapat beberapa celah. Pertama, sebagian besar penelitian sebelumnya berfokus pada segmentasi biner atau multi-label terbatas, misalnya 2–6 subtype perdarahan dan belum banyak mengeksplorasi segmentasi multikelas dengan jumlah kelas besar pada CT kepala, terutama ketika kelas mencakup variasi perdarahan yang lebih rinci. Penelitian ini menempatkan diri sebagai studi yang berkontribusi memberikan bukti empiris tentang kemampuan *Attention U-Net* yang efisien dalam menangani segmentasi perdarahan otak multikelas berukuran besar pada dataset publik, sekaligus menjadi baseline kuat untuk pengembangan model yang lebih kompleks di masa depan.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental berbasis deep learning untuk mengembangkan dan mengevaluasi model Attention U-Net dalam tugas segmentasi perdarahan otak pada citra medis. Seluruh proses pemodelan dan pengujian dilakukan menggunakan Google Colab dengan dukungan GPU, bahasa pemrograman Python, dan pustaka PyTorch sebagai kerangka kerja utama dimana alur penelitian ini ditunjukkan pada Gambar 1 berikut.



Gambar 1. Alur penelitian

Secara umum, alur penelitian terdiri atas beberapa tahap utama :

- a. Akuisisi Data

Pertama, peneliti mengakuisisi data berupa citra CT kepala yang telah dianotasi dari platform Roboflow. Dataset yang diunduh berformat COCO segmentation, sehingga setiap citra CT sudah memiliki informasi label dan poligon area perdarahan yang dapat digunakan sebagai target segmentasi. Data ini kemudian dipisahkan sesuai pembagian train, validation, dan test yang telah tersedia di dataset.

b. Preprocessing dan Augmentasi

Setelah data diperoleh, peneliti melakukan tahap preprocessing agar formatnya sesuai dengan kebutuhan input model *deep learning*. Pada tahap ini file anotasi COCO dikonversi menjadi mask biner atau label piksel per kelas. Selanjutnya seluruh citra dan mask diseragamkan ukurannya agar memiliki dimensi input yang konsisten. Nilai intensitas citra CT juga dinormalisasi untuk membantu kestabilan proses pelatihan. Untuk meningkatkan keragaman data serta mengurangi overfitting, peneliti menambahkan augmentasi seperti rotasi, flipping, perubahan kontras, atau transformasi ringan lain yang tetap mempertahankan karakteristik klinis citra.

c. Pelatihan dan Validasi

Tahap berikutnya adalah pelatihan dan validasi model. Attention U-Net dilatih menggunakan data training, sementara performanya terus dipantau menggunakan data validation pada setiap epoch. Selama proses ini, model mempelajari pola visual perdarahan dari citra CT sekaligus memperbaiki bobot jaringan secara iteratif. Indikator utama yang diamati pada fase pelatihan adalah nilai Dice Coefficient di data validasi, karena metrik ini secara langsung mengukur ketepatan tumpang tindih antara hasil segmentasi model dan mask *ground-truth*.


d. Pengujian & Evaluasi

Terakhir, setelah model mencapai performa terbaik pada validasi, peneliti melakukan pengujian akhir menggunakan data testing yang tidak pernah dilihat model selama pelatihan. Pada tahap ini, keluaran segmentasi model dibandingkan dengan label asli untuk menghitung Dice Coefficient sebagai ukuran akurasi utama. Hasil evaluasi ini menjadi dasar penilaian apakah Attention U-Net mampu melakukan segmentasi perdarahan otak secara konsisten dan akurat pada citra CT kepala.

4. HASIL DAN PEMBAHASAN

4.1. Akuisisi dataset

Dataset yang digunakan berasal dari platform Roboflow, pada sebuah proyek yang berisi citra CT kepala dengan label perdarahan otak[24]. Dataset diunduh dalam format COCO segmentation yang berjumlah 2731 yang terdiri dari 2553 *data training*, 81 *data validation*, dan 97 *data testing*. Dimana data tersebut terdiri dari 15 kelas yang didistribusikan setiap kelas disajikan pada Gambar 2 berikut :





Gambar 2. Distribusi jumlah data dari setiap kelas

Gambar 2 tersebut menunjukkan distribusi jumlah anotasi pada seluruh dataset untuk tiap kelas. Kelas Intracerebral hemorrhage memiliki anotasi paling banyak yaitu 690 data, disusul Subacute intraventricular hemorrhage sebanyak 620 data dan Space occupying lesion for assessment sebanyak 558 data. Kelas menengah seperti Brain edema for assessment sebanyak 405 data dan Cyst sebanyak 309 data masih cukup dominan, sementara beberapa kelas lain jumlahnya rendah seperti Craniopharyngioma sebanyak 18 data, Posterior fossa mass sebanyak 30 data, dan Acute extradural hematoma sebanyak 39 data. Distribusi ini mengindikasikan dataset tidak seimbang sehingga berpotensi memengaruhi proses pelatihan model segmentasi.

4.2. Preprocessing dan Augmentasi


Pada tahap preprocessing, setiap citra CT dikonversi dan di-*resize* menjadi resolusi 256×256 piksel. Anotasi COCO kemudian dikonversi menjadi mask biner berukuran sama dengan citra, di mana piksel dengan nilai 1 merepresentasikan area perdarahan otak, sedangkan nilai 0 adalah latar belakang. Proses ini dilakukan menggunakan pustaka pycocotools untuk menghasilkan *ground truth* mask yang konsisten untuk seluruh citra hasil dari preprocessing ini disajikan pada Gambar 3 berikut.





Gambar 3. Preprocessing data

Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting, dilakukan augmentasi data pada himpunan pelatihan, antara lain rotasi acak, *horizontal atau vertical flip*, *shift scale rotate*, serta modifikasi kecerahan dan kontras. Augmentasi ini tidak diterapkan pada data validasi dan test agar evaluasi tetap merefleksikan kondisi data nyata. Adapun hasil dari augmentasi tersebut disajikan pada Gambar 4 berikut.



Gambar 4. Hasil augmentasi


4.3. Pelatihan dan validasi

Model yang digunakan merupakan pengembangan dari arsitektur U-Net[23] dengan penambahan attention gate. Secara garis besar, model terdiri atas:

- Encoder: lima tingkat *downsampling* berturut-turut dengan blok konvolusi ganda dan operasi *max pooling* untuk mengekstraksi fitur pada berbagai skala.
- Decoder: lima tingkat *upsampling* menggunakan *transposed convolution* yang memulihkan resolusi spasial.
- Skip connection dengan attention gate: fitur dari jalur encoder sebelum setiap *pooling* dihubungkan ke jalur decoder yang bersesuaian melalui attention gate. Attention gate ini belajar untuk menonjolkan fitur yang relevan dengan lesi perdarahan dan menekan area yang tidak penting[8].

- d. Lapisan keluaran: konvolusi 1x1 dengan satu kanal keluaran yang menghasilkan peta probabilitas perdarahan pada setiap piksel yang kemudian diubah menjadi probabilitas melalui fungsi sigmoid.

Arsitektur ini dipilih karena kombinasi kemampuan U-Net dalam segmentasi citra medis dan keunggulan attention gate dalam memfokuskan jaringan pada area lesi yang seringkali kecil dan memiliki batas yang tidak jelas. Proses pelatihan ini menggunakan 20 epoch dan learning rate sebesar $1e-4$ serta menggunakan optimisasi Adam yang menghasilkan kurva loss dan Dice Coefficient yang ditunjukkan pada Gambar 5. berikut.



Gambar 5. Hasil pelatihan model

Dari Gambar 5 tersebut proses pelatihan model Attention U-Net dilakukan selama 20 epoch dengan nilai learning rate 1×10^{-4} dan algoritma optimisasi Adam. Perkembangan nilai loss dan Dice Coefficient pada data pelatihan dan validasi ditunjukkan pada Gambar 5. Hasil pelatihan menunjukkan train loss turun stabil dan train Dice terus naik hingga sekitar 0,75, tetapi val loss hanya membaik di awal lalu berfluktuasi, sementara val Dice naik cepat sampai kisaran 0,5–0,56 lalu naik-turun tanpa tren jelas. Kesenjangan yang makin lebar antara kurva train dan validasi setelah epoch sekitar 6–8 mengindikasikan overfitting: model semakin baik pada data latih tetapi generalisasinya tidak stabil pada data validasi. Kondisi ini kemungkinan dipicu oleh ketidakseimbangan kelas yang kuat, ukuran data validasi yang kecil sehingga metrik mudah beresilasi, serta variasi lesi atau anotasi yang membuat model sulit konsisten. Implikasinya, performa terbaik kemungkinan terjadi di epoch menengah, dan perlu strategi seperti early stopping serta loss atau augmentasi berbobot kelas untuk memperbaiki generalisasi.

4.4. Pengujian dan Evaluasi

Evaluasi kinerja utama dilakukan pada himpunan test yang tidak pernah digunakan selama pelatihan maupun validasi. Metrik utama yang digunakan adalah Dice coefficient, yang mengukur tingkat kesesuaian antara mask prediksi dan ground truth. Hasil evaluasi kuantitatif dan kualitatif ini kemudian digunakan sebagai dasar pembahasan kelebihan dan keterbatasan model dalam konteks aplikasi klinis. Berdasarkan model terbaik yang diperoleh dari proses pelatihan tersebut, evaluasi pada data uji menghasilkan nilai test loss sebesar 0,1935 dan test Dice Coefficient sebesar 0,6696. Nilai Dice sekitar 0,67 menunjukkan bahwa model telah mampu melakukan segmentasi perdarahan otak

dengan tingkat tumpang tindih yang cukup baik terhadap *ground truth*, meskipun masih terdapat ruang perbaikan. Dengan kata lain, sebagian besar area perdarahan sudah berhasil teridentifikasi, namun masih ditemukan beberapa kasus di mana model mengalami under segmentation atau over segmentation, terutama pada lesi berukuran kecil atau dengan kontras yang rendah sehingga mempengaruhi nilai Dice secara keseluruhan.

Hasil eksperimen menunjukkan bahwa integrasi mekanisme attention ke dalam arsitektur U-Net mampu meningkatkan kemampuan segmentasi perdarahan otak pada citra CT. Attention gate yang ditempatkan pada setiap skip connection membantu jaringan untuk memfokuskan perhatian pada fitur yang relevan dengan lesi, sekaligus menekan area latar belakang yang tidak penting[8]. Hal ini tercermin dari segmentasi yang lebih bersih dan kontur lesi yang lebih sesuai dibandingkan yang biasanya diperoleh dari U-Net standar pada dataset serupa [9],[11].

5. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model Attention U-Net mampu digunakan untuk melakukan segmentasi perdarahan otak pada citra CT secara otomatis dengan performa yang cukup baik. Dengan konfigurasi pelatihan 20 epoch, learning rate 1×10^{-4} , dan optimizer Adam, model menghasilkan nilai test loss sebesar 0,1935 dan Dice Coefficient sebesar 0,6696. Nilai ini menunjukkan bahwa sebagian besar area perdarahan telah berhasil teridentifikasi dan dipetakan mendekati ground truth, sehingga model berpotensi membantu proses pengukuran volume dan lokalisasi perdarahan secara lebih cepat dan konsisten dibandingkan segmentasi manual. Meskipun demikian, performa segmentasi pada lesi kecil dan kasus dengan kualitas citra rendah masih perlu ditingkatkan, misalnya melalui penambahan data latih yang lebih bervariasi, penerapan teknik penanganan ketidakseimbangan kelas, atau eksplorasi arsitektur lanjutan berbasis attention dan 3D. Secara keseluruhan, penelitian ini memberikan landasan awal yang menjanjikan bagi pengembangan sistem pendukung keputusan klinis berbasis deep learning untuk kasus perdarahan otak.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat LPPM Universitas Duta Bangsa Surakarta yang telah memberikan dukungan pendanaan sehingga penelitian ini dengan nomor kontrak 154/UDB.LPPM/A.34-HK/IX/2025 dapat terlaksana dengan baik.

DAFTAR PUSTAKA

- [1] R. F. Keep, Y. Hua, and G. Xi, "Intracerebral haemorrhage: mechanisms of injury and therapeutic targets," *Lancet Neurol.*, vol. 11, no. 8, pp. 720–731, Aug. 2012, doi: 10.1016/S1474-4422(12)70104-7.
- [2] A. Hillal, T. Ullberg, B. Ramgren, and J. Wassélius, "Computed tomography in acute intracerebral hemorrhage: neuroimaging predictors of hematoma expansion and

- outcome,” *Insights Imaging*, vol. 13, no. 1, p. 180, Nov. 2022, doi: 10.1186/s13244-022-01309-1.
- [3] D. Haupenthal, S. Schwab, and J. B. Kuramatsu, “Hematoma expansion in intracerebral hemorrhage – the right target?,” *Neurol. Res. Pract.*, vol. 5, no. 1, p. 36, July 2023, doi: 10.1186/s42466-023-00256-6.
- [4] A. Morotti, F. Arba, G. Boulouis, and A. Charidimou, “Noncontrast CT markers of intracerebral hemorrhage expansion and poor outcome: A meta-analysis,” *Neurology*, vol. 95, no. 14, pp. 632–643, Oct. 2020, doi: 10.1212/WNL.0000000000010660.
- [5] N. Venketasubramanian, F. L. Yudiarto, and D. Tugasworo, “Stroke Burden and Stroke Services in Indonesia,” *Cerebrovasc. Dis. Extra*, vol. 12, no. 1, pp. 53–57, Mar. 2022, doi: 10.1159/000524161.
- [6] I. D. Prawesti, A. Selohandono, A. Tejosukmono, N. W. Sukirto, and R. G. P. Putri, “The Association Between Hypertension and Stroke in PKU Muhammadiyah Gamping Hospital,” *J. Kedokt. Diponegoro Diponegoro Med. J.*, vol. 13, no. 6, Oct. 2024, doi: 10.14710/dmj.v13i6.46464.
- [7] Indrastuti, “Digitalisasi Radiologi Percepat Diagnosis Pasien dan Optimalkan Layanan di Rumah Sakit Daerah Terpencil,” *Mediaindonesia*, Apr. 27, 2025. [Online]. Available: https://mediaindonesia.com/humaniora/764995/digitalisasi-radiologi-percepat-diagnosis-pasien-dan-optimalkan-layanan-di-rumah-sakit-daerah-terpencil?utm_source=chatgpt.com
- [8] Z. Piao, Y. H. Gu, H. Jin, and S. J. Yoo, “Intracerebral hemorrhage CT scan image segmentation with HardNet based transformer,” *Sci. Rep.*, vol. 13, no. 1, p. 7208, May 2023, doi: 10.1038/s41598-023-33775-y.
- [9] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” May 18, 2015, *arXiv*: arXiv:1505.04597. doi: 10.48550/arXiv.1505.04597.
- [10] Y. Yuan, Z. Li, W. Tu, and Y. Zhu, “Computed tomography image segmentation of irregular cerebral hemorrhage lesions based on improved U-Net,” *J. Radiat. Res. Appl. Sci.*, vol. 16, no. 3, p. 100638, Sept. 2023, doi: 10.1016/j.jrras.2023.100638.
- [11] H. Wang and X. Wang, “MSRL-Net: An Automatic Segmentation of Intracranial Hemorrhage for CT Images Based on the U-Net Framework,” *Appl. Sci.*, vol. 13, no. 21, p. 11781, Oct. 2023, doi: 10.3390/app132111781.
- [12] O. Oktay *et al.*, “Attention U-Net: Learning Where to Look for the Pancreas,” May 20, 2018, *arXiv*: arXiv:1804.03999. doi: 10.48550/arXiv.1804.03999.
- [13] C. S. Chang, T. S. Chang, J. L. Yan, and L. Ko, “All Attention U-NET for Semantic Segmentation of Intracranial Hemorrhages In Head CT Images,” in *2022 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Oct. 2022, pp. 600–604. doi: 10.1109/BioCAS54905.2022.9948588.
- [14] X. Lin, E. Zou, W. Chen, X. Chen, and L. Lin, “Advanced multi-label brain hemorrhage segmentation using an attention-based residual U-Net model,” *BMC Med. Inform. Decis. Mak.*, vol. 25, no. 1, p. 286, July 2025, doi: 10.1186/s12911-025-03131-3.
- [15] S. N. Ahmed and P. Prakasam, “Intracranial hemorrhage segmentation and classification framework in computer tomography images using deep learning techniques,” *Sci. Rep.*, vol. 15, no. 1, p. 17151, May 2025, doi: 10.1038/s41598-025-01317-3.

- [16] A. Gerbasi *et al.*, “Adapting foundation models for rapid clinical response: intracerebral hemorrhage segmentation in emergency settings,” *Sci. Rep.*, vol. 15, no. 1, p. 28314, Aug. 2025, doi: 10.1038/s41598-025-13742-5.
- [17] Q. Peng *et al.*, “Deep learning-based computed tomography image segmentation and volume measurement of intracerebral hemorrhage,” *Front. Neurosci.*, vol. 16, p. 965680, Oct. 2022, doi: 10.3389/fnins.2022.965680.
- [18] V. Abramova *et al.*, “Hemorrhagic stroke lesion segmentation using a 3D U-Net with squeeze-and-excitation blocks,” *Comput. Med. Imaging Graph.*, vol. 90, p. 101908, June 2021, doi: 10.1016/j.compmedimag.2021.101908.
- [19] M. Yüce, S. Öztürk, G. G. Pamuk, C. Varlık, and A. T. Cimilli, “Automatic segmentation and volumetric analysis of intracranial hemorrhages in brain CT images,” *Eur. J. Radiol.*, vol. 184, p. 111952, Mar. 2025, doi: 10.1016/j.ejrad.2025.111952.
- [20] Y. Zhao, S. Wang, Y. Zhang, S. Qiao, and M. Zhang, “WRANet: wavelet integrated residual attention U-Net network for medical image segmentation,” *Complex Intell. Syst.*, vol. 9, no. 6, pp. 6971–6983, Dec. 2023, doi: 10.1007/s40747-023-01119-y.
- [21] S. Goteti, “Automated classification and segmentation of Intracranial Hemorrhages using 2D Convolutional Neural Networks and U-Net architecture on Computed Tomography scans,” *J. High Sch. Sci.*, vol. 8, no. 4, Dec. 2024, doi: 10.64336/001c.127819.
- [22] B. Pang, L. Chen, Q. Tao, E. Wang, and Y. Yu, “GA-UNet: A Lightweight Ghost and Attention U-Net for Medical Image Segmentation,” *J. Imaging Inform. Med.*, vol. 37, no. 4, pp. 1874–1888, Mar. 2024, doi: 10.1007/s10278-024-01070-5.
- [23] N. A. S and P. P., “Spatial attention-based CSR-Unet framework for subdural and epidural hemorrhage segmentation and classification using CT images,” *BMC Med. Imaging*, vol. 24, no. 1, p. 285, Oct. 2024, doi: 10.1186/s12880-024-01455-6.
- [24] Mohammad Hemeida, “class test 3.” [Online]. Available: <https://universe.roboflow.com/mohammad-hemeida-mkj5z/class-test-3>