



Segmentasi Kepala Janin pada Citra Ultrasound Menggunakan Arsitektur Jaringan U-Net

Fajar Astuti Hermawati^{1*}, Viko Adi Jaya²

^{1,2)} Teknik Informatika, Fakultas Teknik, Universitas 17 Agustus 1945 Surabaya
Jalan Semolowaru 45 Surabaya, Telp: (031)5931800

*email:fajarastuti@untag-sby.ac.id

(Naskah masuk: 18 Januari 2024; diterima untuk diterbitkan: 29 Oktober 2024)

ABSTRAK – Pengolahan citra digital telah dimanfaatkan dalam berbagai bidang, termasuk bidang medis. Salah satu contohnya adalah digunakan untuk mendeteksi letak organ vital pada tubuh manusia. Teknologi ini memungkinkan dokter untuk lebih akurat dalam melakukan diagnosis dan perawatan. Tujuan dari penelitian ini adalah untuk menghasilkan bentuk potongan area kepala janin pada citra ultrasound (USG) dengan menerapkan metode segmentasi deep learning. Tahapan penelitian ini dilakukan dengan akuisisi citra USG, diikuti oleh proses image preprocessing untuk meningkatkan kualitas citra agar hasil proses segmentasi menjadi lebih baik, dilanjutkan dengan penerapan metode segmentasi yang tepat. Penelitian ini berfokus pada penggunaan metode U-Net untuk segmentasi kepala janin pada citra USG. Dengan menggunakan 995 citra USG kepala janin dalam proses training, diperoleh akurasi mini-batch terbaik sebesar 97,10%. Performa hasil segmentasi terhadap 335 citra USG kepala janin pada tahap pengujian dengan menggunakan ukuran koefisien Jaccard diperoleh rata-rata sebesar 87%. Hasil segmentasi ini dapat digunakan untuk keperluan lebih lanjut seperti pengukuran biometrik janin atau untuk visualisasi 3D. Selain itu, metode ini juga berpotensi untuk diterapkan dalam berbagai aplikasi medis lainnya, seperti identifikasi tumor atau kelainan struktural pada organ lain, yang dapat memberikan manfaat besar dalam bidang radiologi dan diagnosis medis.

Kata Kunci – Segmentasi Citra, Citra USG, Kepala Janin, Arsitektur U-NET, Image Preprocessing.

Fetal Head Segmentation in Ultrasound Images Using U-Net Network Architecture

ABSTRACT – Digital image processing has been utilized in various fields, including the medical field. One example is its use in detecting the location of vital organs in the human body. This technology allows doctors to make more accurate diagnoses and treatments. The aim of this research is to produce a cross-sectional image of the fetal head area in ultrasound (USG) images by applying deep learning segmentation methods. The stages of this research involve acquiring USG images, followed by an image preprocessing process to enhance the image quality for better segmentation results, and then applying appropriate segmentation methods. This use of the U-Net method for fetal head segmentation in USG images. Using 995 USG images of fetal heads in the training process, the best mini-batch accuracy obtained was 97.10%. The performance of the segmentation results on 335 USG images of fetal heads in the testing phase, using the Jaccard coefficient measurement, averaged 87%. Segmentation results can be used for further purposes fetal biometric measurements or 3D visualization. This method has the potential applied in various other medical applications, such as the identification of tumors or structural abnormalities in other organs, can provide significant benefits in the fields of radiology and medical diagnosis.

Keywords – Image Segmentation; USG Image; Fetal Head; U-Net Architecture; Image Preprocessing.

1. PENDAHULUAN

Pengembangan teknologi informasi yang semakin cepat berdampak pada kemajuan dalam pengolahan citra digital. Penggunaan citra digital telah dimanfaatkan dalam berbagai bidang, termasuk dalam bidang medis. Salah satu contohnya adalah penggunaan citra digital untuk mendeteksi lokasi organ vital dalam tubuh manusia. Hal ini memberikan manfaat besar dalam diagnosis pasien. Dengan adanya teknologi ini, para profesional medis dapat melakukan diagnosis yang lebih tepat sasaran salah satunya yaitu ultrasonografi (USG) [1]. USG adalah teknik diagnostik pencitraan yang digunakan untuk mendeteksi keberadaan organ penting di dalam tubuh manusia. USG memungkinkan untuk mempelajari bentuk organ, lokasi anatomi, dan gerakan, serta komunikasi dengan jaringan terdekat. Biasanya, bekerja dengan USG bersifat non-invasif, tidak menimbulkan rasa sakit pada pasien, dan dapat diselesaikan dengan cepat dan aman jika dilakukan sesuai dengan standar yang ada [2], [3], [4], [5], [6], [7], [8].

Selain itu, banyak penelitian telah dilakukan dengan topik mendeteksi kelainan anatomi janin menggunakan algoritma berbasis komputer yang digambarkan dalam gambar USG 2D, yang menyoroti pentingnya USG dalam menilai kelainan anatomi janin [3], [4], [5], [6], [8]. Namun, USG 2D memiliki keterbatasan dalam mengubah struktur tubuh manusia secara non-alami, seperti pertumbuhan janin [6].

Terdapat banyak metode segmentasi yang telah diteliti pada citra USG diantaranya yaitu metode *phase-based thresholding* [6], metode *Multiscale Dual Attention-based Network* (MDA-Net) [9], metode U-Net dan V-Net yang ditambahkan dengan CPPN [10], metode OxNNet [11], dan metode *Patch-Of-Interest* (POI) FuseNet [12]. Teknik segmentasi pada citra USG 3D menggunakan metode U-Net yang telah dikembangkan dalam studi [10] mempunyai akurasi tinggi untuk citra 3D. Beberapa metode segmentasi diturunkan dari arsitektur U-Net, seperti RPA-Unet [13], MEF-Unet [14], PDF-UNet [15], BPAT-UNet [16], DMSA-Unet[17], DIM-UNet[18], SIB-Unet[19] dan Attention-VGG16-UNet [20]. Selain itu beberapa penelitian menggabungkan arsitektur UNet dengan arsitektur lain seperti Transformer dan UNet [21] atau melakukan pengembangan arsitektur UNet [22].


Oleh karena itu, penelitian ini berfokus pada penggunaan metode U-Net (*Universal Neural Network*) untuk segmentasi kepala janin pada citra USG. U-Net menyajikan strategi jaringan dan pelatihan yang mengandalkan penggunaan augmentasi data yang kuat untuk menggunakan sampel beranotasi yang tersedia secara lebih efisien. Arsitekturnya terdiri dari jalur kontrak (*contracting*

path) untuk menangkap konteks dan jalur perluasan simetris (*symmetric expanding path*) yang memungkinkan lokalisasi tepat [23] Hasil segmentasi ini dapat digunakan untuk visualisasi 3D. Dengan visualisasi ini bisa memberikan visualisasi yang lebih baik dan informasi yang lebih lengkap tentang struktur internal manusia daripada yang diperoleh dari gambar USG 2D. Segmentasi 3D pada citra USG dapat digunakan sebagai referensi bagi dokter spesialis kandungan dan profesional lainnya untuk mendiagnosis, memahami, dan melakukan penelitian lebih lanjut.

2. METODE PENELITIAN

Dataset

Objek dari penelitian ini adalah citra USG kepala janin. Data yang digunakan dalam penelitian ini tersedia sebagai bagian dari tantangan analisis gambar medis di <https://hc18.grand-challenge.org/> dan di Zenodo, DOI 10.5281/zenodo.1322001 [24] sebanyak 995 citra training set dan 335 citra test set. Sehingga jumlah seluruh dataset yang akan digunakan dalam penelitian ini sebanyak 1330 data. Spesifikasi citra ultrasound yang ada dalam dataset bervariasi ukurannya dengan format ekstensi PNG. Gambar 1 memberikan contoh dari citra ultrasounda dan ground thruth dari area kepala janin.




Gambar 1. Contoh gambar ultrasound dan anotasi area kepala janin

Tahapan Penelitian


Secara keseluruhan, tahapan proses segmentasi dibagi kedalam tiga langkah besar, yaitu persiapan data atau pengolahan awal data (*preprocessing*), tahap pelatihan dengan menggunakan arsitektur U-Net dan tahap pengujian atau implementasi model. Sistem segmentasi ini diimplementasikan dengan menggunakan MATLAB® versi 2022. Langkah awal

pra-pemrosesan citra melibatkan dua tahap utama dapat dilihat pada Gambar 2. Tahap pertama adalah penyesuaian ukuran citra melalui proses *resize*, dimana dimensi citra diubah sesuai dengan format yang diinginkan. Sementara itu, langkah kedua, yaitu pemotongan citra (*cropping*), dilakukan untuk menghilangkan bagian tertentu dari citra yang mungkin tidak diperlukan atau untuk mengatasi masalah komposisi gambar. Proses *resize* diarahkan untuk menjamin konsistensi ukuran citra, sementara pemotongan bertujuan untuk memusatkan pada area yang paling relevan dan mengurangi elemen yang kurang signifikan. Kedua tahap ini merupakan bagian yang tak terpisahkan dari pra-pemrosesan citra, dengan tujuan mempersiapkan data sesuai dengan kebutuhan model yang akan dijalankan.



Gambar 2. Hasil pra-pemrosesan citra

Tahap pelatihan dimulai dengan pembacaan dan pemrosesan gambar melalui *ImageDatastore* dan kemungkinan pemrosesan tambahan sesuai kebutuhan. Variabel *image preprocessing* akan menghasilkan data gambar yang telah diproses untuk tahap berikutnya dalam alur pelatihan model. Proses ini mempersiapkan data gambar yang akan digunakan dalam pelatihan dan melibatkan berbagai operasi *preprocessing* untuk memastikan data siap digunakan dalam model yang akan dilatih, untuk langkah-langkahnya dapat dilihat pada Gambar 3.



Gambar 3. Diagram tahap pelatihan

Penerapan pelatihan model U-Net pada citra medis, terutama untuk mengidentifikasi bagian kepala janin dalam citra ultrasonografi (USG), dimulai dengan serangkaian tindakan awal. Langkah-langkah ini melibatkan persiapan data dan konfigurasi model U-Net untuk segmentasi yang optimal. Proses dimulai dengan mengimpor data pelatihan, menentukan kategori segmentasi yang diperlukan, dan menyesuaikan struktur U-Net yang akan digunakan. Tahap-tahap awal ini bertujuan untuk membentuk dasar sebelum model dapat menjalani proses pelatihan menggunakan dataset

citra medis yang relevan, dimulai dengan langkah-langkah berikut:


Langkah pertama dalam penerapan adalah mengambil data latih menggunakan *imageDir* dan *labelDir* yang menunjukkan direktori penyimpanan citra dan label. Proses ini melibatkan penggunaan *imageDatastore* dan *pixelLabelDatastore* untuk membaca dataset citra dan label yang sesuai. Fungsi *readAndPreprocessImage* kemudian diterapkan untuk membaca dan memproses citra, memastikan bahwa data yang digunakan untuk pelatihan memenuhi persyaratan yang ditetapkan.

Selanjutnya, langkah berikutnya melibatkan definisi kelas-kelas yang akan di-segmentasi, yaitu "Background" dan "Head". Setelah langkah ini selesai, data pelatihan dibentuk menggunakan *randomPatchExtractionDatastore*. Dalam proses ini, citra-citra acak (*patch*) beserta labelnya dihasilkan dari dataset yang telah dipersiapkan. Langkah berikutnya dalam pelaksanaan adalah menetapkan arsitektur U-Net dengan menggunakan fungsi *unetLayers* [23].

Arsitektur Jaringan U-NET

U-Net (*Universal Neural Network*) adalah arsitektur jaringan saraf tiruan yang populer untuk tugas segmentasi gambar, khususnya tugas segmentasi semantic [23], [25]. Arsitektur U-Net awalnya dikembangkan untuk aplikasi segmentasi medis, tetapi sejak itu digunakan dalam berbagai bidang, termasuk pengolahan citra dan penglihatan komputer. U-Net memiliki struktur jaringan yang simetris dan terdiri dari dua bagian utama: *encoder* (pemampat) dan *decoder* (dekompresor). Bagian *encoder* digunakan untuk mengekstraksi fitur dari gambar input, sedangkan bagian *decoder* bertanggung jawab untuk menghasilkan segmentasi piksel [25].

Bagian *encoder* mengalami kontraksi, yang berarti mengurangi dimensi citra dengan lapisan konvolusi dan *max-pooling*. Bagian *decoder* melakukan ekspansi, yang memungkinkan pemulihan informasi spasial yang hilang selama kontraksi. U-Net telah berhasil digunakan dalam berbagai aplikasi, termasuk segmentasi organ medis dalam citra MRI, segmentasi objek dalam citra komputerisasi, segmentasi citra satelit, dan banyak lagi. Ini adalah alat yang kuat untuk tugas segmentasi yang membutuhkan pemahaman kontekstual yang tinggi dari objek dalam citra. Gambar 5 menunjukkan arsitektur U-Net secara lengkap.



Gambar 5. Arsitektur U-Net [23]

Dalam tahap ini, arsitektur U-Net disesuaikan dengan memasukkan parameter seperti dimensi input, jumlah kelas yang diinginkan, dan kedalaman *encoder* yang telah ditetapkan sebelumnya. Setelah itu, data citra dan label yang telah disiapkan sebelumnya digabungkan menggunakan fungsi *combine*. Proses *combine* menyiapkan dataset untuk digunakan dalam pelatihan model, menyatukan informasi citra dan label untuk meningkatkan pembelajaran model U-Net. Setelah merancang struktur U-Net, langkah berikutnya adalah mengonfigurasi opsi pelatihan seperti pada Tabel 1, termasuk pemilihan jenis *optimizer*, tingkat pembelajaran awal, jumlah epoch, ukuran *minibatch*, dan frekuensi tampilan *verbose*. Pilihan untuk menggunakan *optimizer* "sgdm" (*Stochastic Gradient Descent with Momentum*) dipertimbangkan relevan untuk memperbarui parameter model selama pelatihan. Tingkat pembelajaran awal yang didefinisikan pada tingkat 1e-3 bertujuan untuk mengoptimalkan proses konvergensi model. Penetapan jumlah epoch sebesar 20 menunjukkan berapa kali seluruh dataset akan diproses selama pelatihan. Ukuran *minibatch* yang ditetapkan sebesar 4 dipilih untuk mencapai keseimbangan antara kecepatan pelatihan dan penggunaan memori yang efisien. Terakhir, frekuensi tampilan *verbose* pada setiap 10 iterasi memberikan pemantauan yang jelas terhadap kemajuan pelatihan. Dengan opsi pelatihan yang sudah ditentukan, model U-Net dilatih menggunakan fungsi *trainNetwork* dengan memanfaatkan data yang telah disiapkan sebelumnya. Tahap ini merupakan inti dari proses pembentukan model, di mana parameter model diperbarui secara iteratif untuk meminimalkan kesalahan dan meningkatkan kinerja segmentasi citra medis.


Tabel 1. Konfigurasi Opsi Pelatihan

Opsi	Nilai
<i>optimizer</i>	Sgdm
<i>Learning rate</i>	1e-3
<i>epoch</i>	20

<i>Minibatch size</i>	4
<i>Verbose frequency</i>	10

Tahap Segmentasi

Pada tahap proses segmentasi, metode yang digunakan adalah deep learning dengan menggunakan *Convolutional Neural Network* (CNN) berbasis arsitektur U-Net. Langkah-langkah pada proses segmentasi dapat dilihat pada Gambar 4.



Gambar 4. Diagram tahap segmentasi citra

Proses pengujian model U-Net pada data uji (*test set*) dilakukan melalui langkah-langkah tertentu, sebagaimana dijelaskan dalam kode implementasi. Pertama, data uji, berupa gambar dan label, dimuat menggunakan direktori penyimpanan yang telah ditentukan, dan kemudian dikelola oleh objek *'imageDatastore'* dengan fungsi bacaan khusus (*'ReadFcn'*) untuk memproses gambar saat membacanya. Selanjutnya, definisi kelas-kelas untuk segmentasi piksel, seperti "Background" dan "Head", dilakukan bersamaan dengan penetapan indeks yang sesuai untuk setiap kelas.


Selama proses pengujian, sebuah tabel khusus digunakan untuk menyimpan nilai koefisien *Jaccard* atau disebut juga dengan *Intersection over Union* (IoU) [26] yang dihasilkan oleh model pada setiap gambar uji. Melalui *loop* yang berjalan untuk satu iterasi, gambar uji dibaca, dilakukan segmentasi menggunakan model U-Net, dan *overlay* label pada gambar asli untuk tujuan visualisasi. Setelah itu, hasil sebenarnya dari gambar uji dan representasi citra hasil segmentasi dihitung dan ditampilkan secara bersamaan untuk perbandingan. Nilai *Jaccard*, yang mencerminkan sejauh mana hasil segmentasi cocok dengan label sebenarnya, dihitung dan dicatat ke dalam tabel. Koefisien *Jaccard* atau IoU untuk dua buah area A dan B, dirumuskan dalam Persamaan (1)

$$IoU = \frac{\text{Area Of Overlap}}{\text{Area Of Union}} = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$


3. HASIL DAN PEMBAHASAN

Tahap Pelatihan

Dengan menggunakan dataset hasil praproses sebagai input training, proses training dilakukan menggunakan konfigurasi opsi pelatihan pada Tabel 1. Akurasi dari setiap iterasi proses pelatihan disajikan dalam grafik pada Gambar 6. Sedangkan fungsi loss disajikan pada Gambar 7.



Gambar 6. Grafik *mini-batch accuracy* proses pelatihan




Gambar 7. Grafik *mini-batch loss* proses pelatihan


Berdasarkan Gambar 6 dan Gambar 7, ditemukan bahwa *mini-batch accuracy* tertinggi mencapai 97,10%, dan *mini-batch loss* pada akhir pembelajaran sebesar 0.0715. Dengan kata lain, loss terbesar terjadi pada tahap awal pelatihan model dan terus menurun selaras dengan kenaikan dari akurasi.

Tahap Pengujian Segmentasi

Tujuan dari pengujian adalah untuk mengevaluasi sejauh mana model dapat menggeneralisasi dan memberikan hasil segmentasi yang benar pada data yang belum pernah dilihat sebelumnya. Performa dari hasil segmentasi diukur dengan menggunakan IoU atau koefisien Jaccard yang disajikan pada Persamaan (1). Gambar 8 menunjukkan contoh hasil segmentasi menggunakan model U-Net yang telah dilatih sebelumnya. Gambar 8 bagian kiri adalah gambar citra input yang ditimpa dengan label hasil segmentasi yaitu biru untuk area *background* dan hijau untuk area kepala janin. Sedangkan bagian kanan menunjukkan perpotongan antara area ground truth dan area hasil segmentasi sistem. Nilai koefisien Jaccard dari hasil segmentasi pada Gambar 8 mencapai 96,61%.



Gambar 8. Contoh hasil segmentasi area kepala janin



Gambar 9. Diagram nilai koefisien Jaccard hasil segmentasi

Tabel 2. Rata-rata performa hasil segmentasi

<i>Object</i>	<i>IoU</i>
<i>Background</i>	79%
<i>Head</i>	87%

Gambar 9 menunjukkan performa dari hasil segmentasi untuk seluruh citra uji sebanyak 335 dengan rata-rata performa seperti yang disajikan pada Tabel 2. Hasil performa menunjukkan rata-rata nilai Jaccard (IoU) segmentasi untuk daerah kepala mencapai 87% dan mencapai 79% untuk area *background*.

4. KESIMPULAN

Berdasarkan penelitian ini, yang berfokus pada penggunaan metode U-Net (Universal Neural Network) untuk segmentasi kepala janin pada citra USG, ditemukan bahwa metode ini sangat efektif. Pada proses training, *mini-batch accuracy* mencapai 97,10%, menunjukkan keakuratan yang tinggi dalam segmentasi. *Mini-batch loss* pada akhir pembelajaran sebesar 0.0715 menunjukkan bahwa model ini memiliki efisiensi yang baik dalam proses pelatihan. Hasil performa lebih lanjut menunjukkan bahwa rata-rata nilai Jaccard (Intersection over Union atau IoU) untuk segmentasi daerah kepala mencapai 87%, sementara untuk area *background* mencapai 79%. Dengan hasil yang sangat baik ini, metode U-Net terbukti handal dalam segmentasi kepala janin pada citra USG, memberikan kontribusi signifikan untuk aplikasi medis, seperti pengukuran biometrik janin dan visualisasi 3D. Hasil penelitian ini juga menunjukkan potensi untuk diterapkan dalam

berbagai aplikasi diagnostik medis lainnya. Sebagai rekomendasi untuk penelitian mendatang, disarankan untuk mengimplementasikan pengenalan area kepala secara otomatis dan mengujinya untuk menghitung ukuran biometric janin seperti lingkaran kepala janin.

DAFTAR PUSTAKA

- [1] F. A. Hermawati, M. Rajib, and A. Wijaya, "Sistem Deteksi Bagian Tubuh Janin pada Gambar USG 2D untuk Pengukuran Biometrik dengan Kombinasi Metode Aggregated Channel Features (ACF) Detector dan Faster R-CNN," in *Konferensi Nasional Ilmu Komputer (KONIK) 2021*, 2021.
- [2] F. A. Hermawati, Sugiono, and Evonda, "Ultrasound image formation from doppler transducer," in *Springer Proceedings in Physics*, 2017. doi: 10.1007/978-3-319-56062-5_45.
- [3] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Hybrid Speckle Noise Reduction Method for Abdominal Circumference Segmentation of Fetal Ultrasound Images," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, no. 3, pp. 1747-1757, 2018.
- [4] F. A. Hermawati, S. Sugiono, and R. Octaviany, "Restorasi Citra Ultrasound Medis untuk Menghilangkan Speckle Noise dengan Metode Modified Speckle Reducing Anisotropic Diffusion," in *Seminar Nasional Otomasi Industri dan Teknologi Informasi 2015 (SNOITI 2015)*, 2015.
- [5] F. A. Hermawati, H. Tjandrasa, S. Sugiono, and A. Azis, "Automatic Femur Length Measurement for Fetal Ultrasound Image Using Localizing Region-Based Active Contours Method," in *International Conference on Informatics, Robotics, Network, Control and Systems 2016*, Bandung, 2016.
- [6] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Phase-based thresholding schemes for segmentation of fetal thigh cross-sectional region in ultrasound images," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 7, pp. 4448-4460, Jul. 2022, doi: 10.1016/j.jksuci.2021.02.004.
- [7] F. A. Hermawati, H. Tjandrasa, Sugiono, G. I. P. Sari, and A. Azis, "Automatic femur length measurement for fetal ultrasound image using localizing region-based active contour method," *J Phys Conf Ser*, vol. 1230, no. 1, 2019, doi: 10.1088/1742-6596/1230/1/012002.
- [8] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Combination of Aggregated Channel Features (ACF) detector and Faster R-CNN to improve object detection performance in fetal ultrasound images," *International Journal of Intelligent Engineering and Systems*, vol. 11, no. 6, 2018, doi: 10.22266/ijies2018.1231.07.
- [9] A. Iqbal and M. Sharif, "MDA-Net: Multiscale dual attention-based network for breast lesion segmentation using ultrasound images," *Journal of King Saud University - Computer and Information Sciences*, no. xxxx, 2021, doi: 10.1016/j.jksuci.2021.10.002.
- [10] M. Martin, B. Sciolla, M. Sdika, P. Quélin, and P. Delachartre, "Automatic segmentation and location learning of neonatal cerebral ventricles in 3D ultrasound data combining CNN and CPPN," *Comput Biol Med*, vol. 131, no. February, 2021, doi: 10.1016/j.compbiomed.2021.104268.
- [11] P. Looney et al., "Fully automated, real-time 3D ultrasound segmentation to estimate first trimester placental volume using deep learning," *JCI Insight*, vol. 3, no. 11, Jun. 2018, doi: 10.1172/jci.insight.120178.
- [12] L. S. Hesse et al., "Subcortical segmentation of the fetal brain in 3D ultrasound using deep learning," *Neuroimage*, vol. 254, Jul. 2022, doi: 10.1016/j.neuroimage.2022.119117.
- [13] K. Luo et al., "RPA-UNet: A robust approach for arteriovenous fistula ultrasound image segmentation," *Biomed Signal Process Control*, vol. 95, Sep. 2024, doi: 10.1016/j.bspc.2024.106453.
- [14] M. Xu, Q. Ma, H. Zhang, D. Kong, and T. Zeng, "MEF-UNet: An end-to-end ultrasound image segmentation algorithm based on multi-scale feature extraction and fusion," *Computerized Medical Imaging and Graphics*, vol. 114, Jun. 2024, doi: 10.1016/j.compmedimag.2024.102370.
- [15] A. Iqbal and M. Sharif, "PDF-UNet: A semi-supervised method for segmentation of breast tumor images using a U-shaped pyramid-dilated network," *Expert Syst Appl*, vol. 221, Jul. 2023, doi: 10.1016/j.eswa.2023.119718.
- [16] H. Bi et al., "BPAT-UNet: Boundary preserving assembled transformer UNet for ultrasound thyroid nodule segmentation," *Comput Methods Programs Biomed*, vol. 238, Aug. 2023, doi: 10.1016/j.cmpb.2023.107614.
- [17] X. Li, C. Fu, Q. Wang, W. Zhang, C. W. Sham, and J. Chen, "DMSA-UNet: Dual Multi-Scale Attention makes UNet more strong for medical image segmentation," *Knowl Based Syst*, vol. 299, Sep. 2024, doi: 10.1016/j.knosys.2024.112050.
- [18] G. Li, Y. Zheng, J. Cui, W. Gai, and M. Qi, "DIM-UNet: Boosting medical image segmentation via diffusion models and information bottleneck theory mixed with MLP," *Biomed Signal Process Control*, vol. 91, May 2024, doi: 10.1016/j.bspc.2024.106026.

- [19] G. Li and M. Qi, "SIB-UNet: A dual encoder medical image segmentation model with selective fusion and information bottleneck fusion," *Expert Syst Appl*, vol. 252, Oct. 2024, doi: 10.1016/j.eswa.2024.124284.
- [20] A. Huang, L. Jiang, J. Zhang, and Q. Wang, "Attention-VGG16-UNet: a novel deep learning approach for automatic segmentation of the median nerve in ultrasound images," *Quant Imaging Med Surg*, vol. 12, no. 6, pp. 3138–3150, Jun. 2022, doi: 10.21037/qims-21-1074.
- [21] L. Cai, Q. Li, J. Zhang, Z. Zhang, R. Yang, and L. Zhang, "Ultrasound image segmentation based on Transformer and U-Net with joint loss," *PeerJ Comput Sci*, vol. 9, pp. 1–18, 2023, doi: 10.7717/peerj-cs.1638.
- [22] N. R. Shenoy and A. Jatti, "Ultrasound image segmentation through deep learning based improvised U-net," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 21, no. 3, pp. 1424–1434, Mar. 2021, doi: 10.11591/ijeecs.v21.i3.pp1424-1434.
- [23] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *ArXiv*, vol. 1505.04597, 2015, doi: <https://doi.org/10.48550/arXiv.1505.04597>.
- [24] T. L. A. van den Heuvel, D. de Bruijn, C. L. de Korte, and B. van Ginneken, "Automated measurement of fetal head circumference using 2D ultrasound images," *PLoS One*, vol. 13, no. 8, Aug. 2018, doi: 10.1371/journal.pone.0200412.
- [25] J. O. Healthcare Engineering, "Retracted: U-Net-Based Medical Image Segmentation," *Journal of healthcare engineering*, vol. 2023, p. 9890389, 2023. doi: 10.1155/2023/9890389.
- [26] D. Ogwok and E. M. Ehlers, "Jaccard Index in Ensemble Image Segmentation: An Approach," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Nov. 2022, pp. 9–14. doi: 10.1145/3581792.3581794.