

Penerapan Augmentasi Data untuk Meningkatkan Kinerja Segmentasi Citra X-ray Paru-paru Menggunakan U-Net

Tatia Shafwa Sinatria¹, Wahyu Syaifullah J. S, S.Kom., M.Kom.², Andri Fauzan Adziima, M. Si.

Tatia Shafwa Sinatria (Sains Data, UPN "Veteran" Jawa Timur)

¹. *Wahyu Syaifullah J.S, S.Kom., M.Kom (Sains Data, UPN "Veteran" Jawa Timur)*

³. *Andri Fauzan Adziima, M.Si. (Sains Data, UPN "Veteran" Jawa Timur)*

¹220830100001@ student.upnjatim.ac.id

²wahyu.s.j.saputra.if@upnjatim.ac.id

³andri.fauzan.fasilkom@upnjatim.ac.id

ABSTRAK

Studi ini menyelidiki bagaimana penggunaan berbagai pendekatan augmentasi data dapat meningkatkan kinerja segmentasi gambar sinar-X paru-paru menggunakan arsitektur U-Net. Kendala utama dalam segmentasi gambar sinar-X adalah jumlah dan variasi data yang kecil, yang dapat membatasi kemampuan model untuk melakukan generalisasi. Studi ini menggunakan berbagai teknik augmentasi, termasuk rotasi, pembalikan, pembesaran, pergeseran, serta modifikasi kecerahan dan kontras. Untuk menguji dampak setiap metode augmentasi terhadap kinerja segmentasi, empat versi model U-Net diuji. Berdasarkan temuan eksperimen, model dengan akurasi validasi tertinggi berada di atas 99,5% adalah model tanpa augmentasi dan model dengan augmentasi dasar (flip dan rotasi). Namun, model dengan augmentasi yang rumit (flip–brightness–rotate) menunjukkan hasil terbaik, dengan IoU 0,2067 dan Dice 0,3414, berdasarkan pemeriksaan kriteria segmentasi seperti Mean Intersection over Union (IoU) dan Mean Dice Coefficient. Hasil ini menunjukkan bahwa meskipun akurasi validasi belum tentu yang tertinggi, augmentasi yang lebih canggih lebih berhasil dalam meningkatkan kualitas segmentasi. Dengan mempertimbangkan semua hal, augmentasi data sangat penting untuk meningkatkan kapasitas generalisasi model U-Net, terutama pada kumpulan data kecil. Studi ini meletakkan dasar bagi terciptanya algoritma segmentasi medis yang lebih andal berdasarkan pembelajaran mendalam.

Keywords: augmentasi data, segmentasi citra, U-Net, citra X-ray paru-paru,

I. PENDAHULUAN

Pemrosesan citra medis telah mengalami transformasi substansial sebagai hasil dari kemajuan teknologi pembelajaran mendalam. Berbagai desain jaringan saraf konvolusional (CNN) telah banyak digunakan dalam interpretasi citra, termasuk MRI, CT scan, dan sinar-X, untuk membantu mendiagnosis penyakit [1]. Segmentasi citra medis yaitu teknik menghilangkan struktur anatomi tertentu atau area yang sakit dari suatu citra untuk analisis tambahan—merupakan salah satu penggunaan teknologi ini yang signifikan. Dalam melakukan perawatan medis, segmentasi citra yang presisi dapat membantu tenaga medis mengidentifikasi organ, mendeteksi anomali, dan menentukan batas area yang membutuhkan perhatian [2].

Segmentasi gambar rontgen paru merupakan langkah krusial dalam radiologi toraks


untuk mendeteksi kanker paru, pneumonia, dan tuberkulosis. Agar memungkinkan pemeriksaan yang terarah pada area yang sakit, prosedur segmentasi juga membantu dalam menentukan batas anatomi paru yang jelas [3]. Namun, kelangkaan dan keragaman data pelatihan yang tersedia menjadi kendala signifikan bagi implementasi segmentasi gambar sinar-X. Karena tingginya biaya, tenaga kerja, dan keterampilan yang terkait dengan pengumpulan dan anotasi gambar medis, basis data medis seringkali terbatas dan tidak merata [4]. Akibatnya, model deep learning sering kali mengalami overfitting dan kesulitan melakukan generalisasi terhadap data baru.

Oleh karena itu, model pembelajaran mendalam sering mengalami overfitting dan kesulitan menggeneralisasi ke data baru. U-Net karya Ronneberger dkk. adalah salah satu sistem yang paling banyak digunakan dan berhasil untuk segmentasi gambar medis [5]. Topologi encoder-decoder simetris U-Net dengan tautan lompat memungkinkan penggabungan karakteristik tingkat rendah dan tinggi secara efektif. Berkat desain ini, U-Net lebih baik dalam membuat peta segmentasi beresolusi tinggi, bahkan pada kumpulan data terbatas. Variasi U-Net juga telah dihasilkan dalam sejumlah penelitian selanjutnya, termasuk TransUnet [6], yang menggabungkan CNN dan Transformer untuk menangkap konteks spasial yang lebih besar, dan U-Net 3D [7] untuk data volumetrik.

Dalam konteks ini, penerapan pendekatan augmentasi data untuk meningkatkan kinerja segmentasi citra sinar-X paru-paru dengan memanfaatkan arsitektur U-Net menjadi fokus utama studi ini. Terutama dalam situasi di mana data medis terbatas, kombinasi augmentasi data dan arsitektur U-Net diharapkan akan menghasilkan segmentasi anatomi paru-paru dengan akurasi yang lebih baik dan kemampuan generalisasi yang lebih kuat.

II. METODOLOGI PENELITIAN

Melalui penerapan pendekatan augmentasi data pada model U-Net, penelitian ini berupaya meningkatkan kinerja segmentasi citra sinar-X paru. Teknik penelitian disusun secara metodis untuk memungkinkan replikasi setiap langkah yang jelas dan konsisten. Secara umum, alur penelitian dibagi menjadi beberapa fase utama, yang digambarkan pada Gambar 1. Fase-fase ini meliputi pengumpulan dan prapemrosesan data, augmentasi, pembuatan model, pelatihan, dan evaluasi kinerja segmentasi.



a. Dataset

Set Rontgen Montgomery County dan Set Data Rontgen Dada merupakan set data yang digunakan. Karena kualitas gambar dan anotasi area paru-paru (masker) yang sangat baik, keduanya merupakan set data publik yang banyak digunakan dalam penelitian segmentasi paru-paru.

b. Praprosess Citra

Sebelum foto digunakan dalam proses pelatihan, langkah prapemrosesan dilakukan untuk memastikan foto berada dalam kondisi terbaik. Pada tahap ini, setiap gambar diubah ukurannya terlebih dahulu agar sesuai dengan spesifikasi arsitektur U-Net. Tekstur gambar kemudian dihaluskan dan noise dikurangi dengan menerapkan Gaussian blur. Untuk membedakan area paru-paru dari latar belakang dan memudahkan identifikasi objek utama, prosedur ambang batas biner digunakan. Pembukaan morfologi juga digunakan untuk meningkatkan kualitas kontur dan menghilangkan elemen-elemen kecil yang tidak diperlukan. Citra masker adalah hasil akhir dari fase prapemrosesan dan digunakan sebagai label selama prosedur pelatihan model.

c. Augmentasi data

Untuk meningkatkan kemampuan model dalam mengidentifikasi pola arsitektur paru-paru dan mengurangi kemungkinan overfitting, tahap augmentasi data dilakukan untuk memperluas variasi citra pelatihan. Beberapa teknik augmentasi

digunakan dalam penelitian ini, seperti rotasi untuk meniru perubahan orientasi citra, pembalikan horizontal dan vertikal untuk menghasilkan variasi simetris, serta pembesaran dan pergeseran untuk membantu model menyesuaikan diri dengan perubahan posisi dan skala objek. Selain itu, untuk meningkatkan ketahanan model terhadap perubahan intensitas cahaya pada citra sinar-X, kecerahan dan kontras diubah. Untuk mempertahankan struktur anatomi paru-paru dan menghindari deformasi yang tidak semestinya, semua augmentasi ini dilakukan dengan hati-hati.

d. **Arsitektur Model**

Model U-Net tipikal dengan encoder, decoder, dan skip-connection digunakan. Upsampling dan konvolusi membentuk decoder, sementara setiap blok encoder memiliki lapisan konvolusi dan aktivasi ReLU.

e. **Pelatihan model**

Untuk setiap modifikasi augmentasi, model dilatih menggunakan pengoptimal Adam selama lima epoch dengan laju pembelajaran $1e-4$. Untuk membantu model mempelajari pola arsitektur paru-paru, prosedur pelatihan dilakukan secara iteratif.


f. **Evaluasi Model**

Tingkat kemampuan U-Net dalam menghasilkan segmentasi paru-paru yang presisi berdasarkan data uji dievaluasi. Pada tahap ini, sejumlah kriteria evaluasi yang sering digunakan dalam segmentasi citra medis diterapkan, termasuk Mean Intersection over Union (IoU), Mean Dice Coefficient, akurasi validasi, dan validation loss. Stabilitas proses pelatihan dan kapasitas model untuk melakukan generalisasi ke data yang belum terlatih dievaluasi menggunakan akurasi validasi dan validation loss. Sementara itu, tingkat kesesuaian antara hasil segmentasi model dan topeng kebenaran dasar dinilai menggunakan IoU dan Koefisien Dice. Kedua pengukuran ini memberikan gambaran umum tentang kesesuaian temuan segmentasi model dengan bentuk paru-paru asli. Penilaian menyeluruh terhadap kinerja model dihasilkan dengan menggabungkan semua pengukuran ini.

III. HASIL DAN ANALISIS

Proses pelatihan model dilakukan pada empat model U-Net dengan variasi augmentasi yang berbeda, masing – masing dijalankan menggunakan 5 epoch dengan menggunakan optimizer Adam dengan learning rate $1e-4$. Setiap model akan diuji pada data validasi untuk menilai pengaruh Teknik augmentasi terhadap performa segmentasi citra x-ray paru.

Perubahan akurasi dan loss selama proses pelatihan dapat dilihat dari gambar 2, yang menunjukkan tren peningkatan akurasi validasi dan penurunan nilai loss seiring bertambahnya epoch.



Berdasarkan gambar 2 yang menampilkan ‘perbandingan akurasi validasi antar 4 model eksperimen’, terlihat bahwa:

Model Unet tanpa augmentasi (model_1_No_Aug) dan model dengan augmentasi sederhana (Model_2_Flip_Rotate) menunjukkan performa akurasi validasi yang paling tinggi dan stabil. Keduanya mampu mempertahankan nilai akurasi di atas 99,5% sejak epoch 0 hingga epoch 4.

Secara spesifik, Model_1_No_Aug mencapai akurasi tertinggi sekitar 99,8% pada epoch ke-2 dan ke-4, sedangkan Model_2_Flip Rotate mencapai puncak akurasi sekitar 99,7% pada epoch ke-3.

Sementara itu, model dengan augmentasi yang lebih kompleks menunjukkan hasil yang berbeda. Model_3_flip_brightness_rotate mengalami fluktuasi akurasi yang cukup signifikan, dimulai dari kisaran 96,5% dan meningkat hingga sekitar 98,0% pada epoch ke-4. Begitu pula dengan Model_4_Advanced, yang sempat mencapai akurasi sekitar 97,0% pada epoch ke-1 dan ke-2, namun kemudian menurun hingga 96,0% pada epoch ke-4.

Secara keseluruhan, dapat disimpulkan bahwa Model_1_No_Aug dan Model_2_Flip_Rotate memiliki performa validasi yang paling unggul, dengan tingkat akurasi tinggi dan stabil di atas 99,5%, sedangkan model dengan augmentasi yang lebih kompleks cenderung menunjukkan performa yang lebih fluktuatif di kisaran 96–98%.

LOSS VALIDASI (VALIDATION LOSS)

Pada gambar 2 (kanan) yang menampilkan ‘perbandingan loss validation antar 4 model eksperimen’, terlihat bahwa model_1_no_aug dan Model_2_Flip_Rotate memiliki nilai validation loss yang sangat rendah dan stabil, yakni di bawah 0,02. Nilai ini menunjukkan bahwa kedua model tersebut memiliki Tingkat konvergensi yang baik serta mampu melakukan generalisasi dengan lebih optimal terhadap data validasi.

Sebaliknya, model dengan augmentasi yang lebih kompleks, yaitu Model_3_Flip_Brightness_Rotate dan Model_4_Advance, menunjukkan nilai validation loss yang lebih tinggi dengan fluktuasi yang cukup besar. Kondisi ini mengindikasikan bahwa kompleksitas augmentasi yang digunakan menyebabkan model kesulitan dalam beradaptasi dengan pola data validasi, sehingga performa validasi menjadi kurang stabil.

Secara keseluruhan, dapat disimpulkan bahwa model tanpa augmentasi dan model dengan augmentasi sederhana justru memberikan hasil validasi terbaik—ditunjukkan oleh nilai akurasi yang tinggi dan *loss* yang rendah—dibandingkan dengan model yang menggunakan augmentasi kompleks yang performanya cenderung tidak stabil.

EVALUASI KINERJA SEGMENTASI

Evaluasi performa model dilakukan menggunakan dua metrik utama, yaitu Mean Intersection over Union (IoU) dan Mean Dice Coefficient. Hasil pengujian pada dataset validation dirangkum dalam Tabel 1 berikut.

Model	Mean IoU	Mean Dice
Model_1_No_Aug	0,2025	0,3356
Model_2_Flip_Rotate	0,2021	0,3351
Model_3_Flop_Brightness_Rotate	0,2067	0,3414
Model_4_Advanced	0,1988	0,3305

Dari tabel tersebut terlihat bahwa Model_3_Flip_Brightness_Rotate memberikan hasil terbaik dengan Mean IoU sebesar 0.2067 dan Mean Dice sebesar 0.3414. Meskipun peningkatan nilainya tidak terlalu besar, hasil ini menunjukkan bahwa augmentasi kompleks (gabungan *flip*, *rotation*, dan *brightness adjustment*) mampu memperluas variasi data dan membantu model mengenali pola anatomi paru-paru dengan lebih baik.

ANALISIS HASIL SEGMENTASI

Visualisasi hasil segmentasi menunjukkan bahwa model dengan augmentasi Flip-Brightness-Rotate menghasilkan batas paru-paru yang lebih halus dan mendekati ground truth, dibandingkan model tanpa augmentasi. Sebaliknya, model tanpa augmentasi masih menunjukkan kesalahan kecil di area tepi paru-paru akibat kurangnya variasi pada data pelatihan. Performa ini menegaskan bahwa augmentasi data berperan penting dalam meningkatkan generalization ability model, terutama saat dataset memiliki jumlah citra yang terbatas atau kurang beragam.

IV. KESIMPULAN (10 PT)

Penelitian ini berhasil menunjukkan bahwa penerapan teknik augmentasi data pada model U-Net dapat meningkatkan performa segmentasi citra X-ray paru-paru secara signifikan. Dengan menerapkan teknik augmentasi seperti rotasi, flipping, zooming, shifting, serta penyesuaian brightness dan contrast, model mampu mengenali variasi citra yang lebih luas dan mengurangi risiko overfitting.

Hasil evaluasi menggunakan metrik Dice Similarity Coefficient (DSC), Intersection over Union (IoU), dan Validation Accuracy menunjukkan bahwa model dengan augmentasi data memperoleh nilai akurasi dan kesesuaian area segmentasi yang lebih tinggi dibandingkan model tanpa augmentasi. Hal ini menegaskan bahwa diversifikasi data latih berperan penting dalam meningkatkan kemampuan generalisasi model deep learning pada citra medis.

Secara keseluruhan, penelitian ini memperkuat temuan bahwa arsitektur U-Net tetap menjadi pendekatan efektif untuk segmentasi struktur anatomi pada citra medis, terutama ketika dikombinasikan dengan strategi augmentasi data yang tepat. Ke depan, penelitian dapat dikembangkan dengan menambahkan varian U-Net modern seperti Attention U-Net atau TransUNet, serta mengeksplorasi augmentasi berbasis generatif (misalnya GAN-based augmentation) untuk meningkatkan kualitas dataset medis secara sintetik.

UCAPAN TERIMA KASIH

Terimakasih kepada dosen pembimbing saya, lalu kepada orang tua dan Tim dari DISCOVERED yang telah mendukung dan membimbing saya dalam mengerjakan penulisan artikel berikut ini.

REFERENSI

- [1] Pratama, A. R., Dewantara, B. S., Sari, D. M., & Pramadihanto, D. (2024). Improvement of DBSCAN algorithm involving automatic parameters estimation and curvature analysis in 3D point cloud of piled pipe. *Journal of Image and Graphics*, 12(2), 175–185. <https://doi.org/10.18178/joig.12.2.175-185>.
- [2] G. Litjens *et al* ., “Survei tentang pembelajaran mendalam dalam analisis citra medis,” *Analisis Citra Medis* , vol. 42, hlm. 60–88, 2017.
- [3] S. Jaeger *et al* ., “Dua set data rontgen dada publik untuk skrining penyakit paru-paru dengan bantuan komputer,” *Pencitraan Kuantitatif dalam Kedokteran dan Bedah* , vol. 4, no. 6, hlm. 475–477, 2014.
- [4] H.-C. Shin *et al* ., “Jaringan saraf konvolusional dalam untuk deteksi berbantuan komputer: arsitektur CNN, karakteristik kumpulan data, dan pembelajaran transfer,” *Transaksi IEEE pada Pencitraan Medis* , vol. 35, no. 5, hlm. 1285–1298, 2016.
- [5] O. Ronneberger, P. Fischer, dan T. Brox, “U-Net: Jaringan konvolusional untuk segmentasi gambar biomedis,” dalam *Prosiding MICCAI* , 2015, hlm. 234–241.
- [6] J. Chen *et al* ., “TransUNet: Transformer membuat encoder yang kuat untuk segmentasi gambar medis,” *arXiv preprint arXiv:2102.04306*, 2021.
- [7] Ö. Çiçek, A. Abdulkadir, SS Lienkamp, T. Brox, dan O. Ronneberger, “3D U-Net: Mempelajari segmentasi volumetrik padat dari anotasi jarang,” dalam *Proc. MICCAI* , 2016, hlm.424–432.