

# PEMANFAATAN DEEP LEARNING UNTUK SEGMENTASI PARU-PARU DARI CITRA X-RAY DADA

(UTILIZATION OF DEEP LEARNING TO SEGMENT THE LUNGS FROM CHEST X-RAY IMAGES)

Dinar Wakhid Putranto<sup>1)</sup>, Andi Sunyoto<sup>2)</sup>, dan Asro Nasiri<sup>3)</sup>

<sup>1)</sup>Magister Teknik Informatika Universitas Amikom Yogyakarta, <sup>2,3)</sup>Universitas Amikom Yogyakarta  
Jl. Padjajaran Ringroad Utara, Condongcatur, Depok, Sleman, DIY  
e-mail: [dinarwp@students.amikom.ac.id](mailto:dinarwp@students.amikom.ac.id)<sup>1)</sup>, [andi@amikom.ac.id](mailto:andi@amikom.ac.id)<sup>2)</sup>, [asro@amikom.ac.id](mailto:asro@amikom.ac.id)<sup>3)</sup>

## ABSTRAK

Pemeriksaan rontgen dada atau thoraks merupakan pemeriksaan penunjang yang paling umum digunakan dalam pendiagnosaan penyakit paru-paru. Selain karena cepat pemeriksaan rontgent lebih ekonomis dibandingkan pemeriksaan CT-scan atau pemeriksaan darah di laborat. Sebelum menentukan penyakit yang tampak dari gambar paru-paru di dalam citra rontgent dada, dokter terlebih dahulu menentukan batas area paru-parunya. Tidak setiap citra X-Ray dada memiliki gambaran paru-paru yang normal, sebagian menampilkan gambaran yang tidak normal terlihat kabut putih atau perubahan morfologi dikarenakan adanya proses penyakit paru-paru. Sebagai salah satu arsitektur dari CNN yang dapat digunakan dalam melakukan segmentasi paru-paru adalah UNET yang merupakan arsitektur encode-decoder. Penelitian ini mencoba untuk melatih model pembelajaran mendalam dengan arsitektur CNN U-Net. Dari hasil percobaan yang kami lakukan model yang diusulkan tersebut dapat menunjukkan kemampuan dalam mengenali batas paru-paru meskipun terdapat gambaran paru-paru yang tidak normal atau berkabut. Performa dari model dihitung dengan mengukur nilai akurasi piksel dan nilai tumpang tindih dengan Jaccard Index (IoU), didapatkan nilai keduanya secara berurutan adalah 98,25% dan 94,54%.

**Kata Kunci:** paru-paru, pembelajaran mendalam, rontgen, segmentasi.

## ABSTRACT

Chest or thoracic X-ray examination is the most commonly used supporting examination in the diagnosis of lung diseases. In addition to being quick, X-rays are more economical than CT scans or laboratory blood tests. Before determining the disease that appears from the lung image in the chest X-ray image, the doctor first determines the boundaries of the lung area. Not every chest X-Ray image has a normal lung image, some display abnormal images that look white haze or morphological changes due to lung disease processes. As one of the CNN architectures that can be used in segmenting the lungs is UNET which is an encode-decoder architecture. This research tries to train a deep learning model with U-Net CNN architecture. From the results of our experiments, the proposed model can show the ability to recognize lung boundaries even though there are abnormal or foggy lung images. The performance of the model is calculated by measuring the pixel accuracy value and the overlap value with Jaccard Index (IoU), the values of both are 98.25% and 94.54% respectively.

**Keywords:** deep learning, lung, segmentation, x-ray.

## I. PENDAHULUAN

Pemeriksaan rontgen dada merupakan pemeriksaan penunjang yang paling umum digunakan dalam menentukan diagnosa penyakit paru-paru. Hal ini dikarenakan pemeriksaan rontgen mudah dilakukan oleh rumah sakit dengan biaya operasional yang rendah dan risiko radiasi yang wajar. Ada banyak penyakit paru-paru yang dapat ditegakkan berdasarkan pemeriksaan X-Ray dada, misalnya seperti tuberkulosis, pneumothorax, emfisema, dan lain-lain. Apabila tidak didiagnosa sejak awal penyakit-

penyakit tersebut dapat menyebabkan kondisi kesehatan yang buruk atau bahkan kematian. Untuk dapat meningkatkan performa dalam proses deteksi penyakit diperlukan sistem *Computer Assisted Diagnostic* (CAD) yang handal. Sistem CAD yang handal perlu mendukung lebih banyak variasi dari bentuk paru-paru yang dimungkinkan mengalami perubahan morfologi dikarenakan terdapat penyakit di dalamnya[1].

Segmentasi sebagai salah satu proses yang tidak terpisahkan dari CAD dalam melakukan klasifikasi penyakit. Segmentasi paru-paru pada citra X-Ray dada dapat dilakukan menggunakan metode

pengolahan citra seperti deteksi tepi menggunakan teknik *Canny Edge*[2] yang mana teknik tersebut dapat menunjukkan performa hingga 80,9% untuk skor IoU. Teknik tersebut tidak memerlukan dataset yang banyak untuk melakukan pengembangan namun akan sangat menyulitkan apabila terdapat banyak citra dalam jumlah besar yang harus disegmentasi. Berikutnya teknik deteksi tepi untuk mengenali batas paru-paru dikembangkan dengan menambahkan struktur *Random Forest* menjadi *Structured Edge Detection* (SED)[3]. Teknik tersebut dapat menunjukkan performa yang lebih tinggi daripada sekedar teknik deteksi tepi sebelumnya, namun teknik SED mengalami kegagalan di dalam menentukan batas tepi dari paru-paru pada citra *X-Ray* dada yang memiliki perubahan morfologi paru-paru karena penyakit tertentu. Percobaan untuk melakukan segmentasi paru-paru juga dilakukan oleh Zotin menggunakan deteksi tepi yang dipadukan dengan *Otsu Thresholding* kemudian dilanjutkan dengan ekstraksi fitur menggunakan GLCM untuk klasifikasi penyakit[4]. Pada percobaan tersebut citra *X-Ray* dada diberi perlakuan *Noise Reduction* dan *Contrast Adjustment* agar kualitas gambar meningkat menjadi lebih jelas. Dari hasil segmentasi didapatkan nilai IoU 91,5%.

Tantangan di dalam melakukan segmentasi untuk jumlah citra yang cukup banyak dapat diatasi dengan memanfaatkan *Deep Learning* (DL) sebagai metode dalam melatih kemampuan komputer. Seiring dengan perkembangan teknologi GPU saat ini DL dapat dikembangkan dengan memanfaatkan kemampuan GPU dalam melakukan pelatihan segmentasi citra[1]. Pelatihan model segmentasi menggunakan metode DL dapat memanfaatkan Jaringan Konvolusi Penuh yang membaca Input berupa citra dan mengeluarkan Output dalam bentuk kemungkinan atau probabilitas setiap piksel sebagai paru-paru atau bukan.

Segmentasi berdasarkan klasifikasi piksel dapat menggunakan metode *Shallow Learning* (SL) dan DL. Metode DL dapat mengungguli performa dari SL yang mana SL melakukan ekstraksi fitur menggunakan metode konvensional[5]. Segmentasi citra medis menggunakan metode DL yang populer menggunakan SegNet dan U-Net. Arsitektur U-Net pertama kali ditemukan dan diperkenalkan oleh[6] sebagai model Jaringan Konvolusi Penuh yang terdiri dari bagian *encoder*

dan *decoder*. Arsitektur tersebut tidak mengalami kesulitan dalam melakukan pembelajaran untuk segmentasi meskipun jumlah dataset pada citra medis yang terbatas.

Problem dari pelatihan model DL adalah kebutuhan akan dataset dalam jumlah yang sangat besar sedangkan dataset dari bidang medis sangat terbatas sehubungan dengan sulitnya mendapatkan data pemeriksaan pasien secara bebas. Untuk mengatasi hal tersebut diperlukan sebuah arsitektur DL yang dapat dilatih dengan jumlah dataset terbatas. Penelitian ini mencoba untuk membuktikan bahwa metode segmentasi menggunakan arsitektur CNN U-Net dapat dilatih meskipun hanya dengan jumlah dataset yang sedikit sebagaimana pada saat U-Net diperkenalkan[6].

## II. STUDI PUSTAKA

Di dalam melaksanakan tugas segmentasi paru-paru dari citra *X-Ray* dada dapat dilakukan berbagai metode mulai dari metode yang sederhana seperti pengolahan citra konvensional hingga metode yang menggunakan teknik pembelajaran mesin. Salah satu metode menggunakan teknik pengolahan citra dapat menggunakan teknik deteksi tepi[3]. Pada penelitian tersebut gambar *X-Ray* dada diambil dari dataset publik JSRT. Untuk mendapatkan area dari paru-paru yang diinginkan dilakukan beberapa tahapan yang dilakukan yaitu dimulai dengan melakukan deteksi tepi menggunakan *Structured Edge Detector* (SED) yang dikembangkan dari *Random Decision Forest*. Untuk menentukan batas tulang dada dan tulang rusuk digunakan metode *Canny Edge Detector*. Metode yang dilakukan tersebut menunjukkan performa yang baik dalam mendeteksi batas paru-paru dengan nilai IoU 94,6%. Metode tersebut memiliki kelemahan dalam mendeteksi batas paru-paru pada citra *X-Ray* dada dengan gambaran paru-paru berkabut. Untuk gambar paru-paru berkabut tidak berhasil dilakukan deteksi tepi sehingga area paru-paru tidak dapat ditentukan dan terkadang berhasil pada sebagian citra namun area paru-paru tidak rasional.

Percobaan untuk melakukan segmentasi paru-paru dari citra *X-Ray* dada juga dilakukan oleh[4] menggunakan teknik deteksi tepi yang dikolaborasi dengan *Otsu Thresholding* untuk mendapatkan batas area paru-paru. Agar paru-paru

menjadi bersih dan tegas ditambahkan tahapan *Noise Reduction* dan *Contrast Adjustmen*. Dari hasil tersebut dilakukan ekstraksi fitur menggunakan GLCM, tidak hanya sampai segmentasi namun hasil ekstraksi fitur digunakan untuk melakukan klasifikasi menggunakan *Probability Neural Network* (PNN) untuk menentukan apakah paru-paru normal atau tidak normal. Performa dari model segmentasi menunjukkan nilai IoU 91,5% sedangkan tingkat akurasi dari klasifikasi menunjukkan angka pada rentang 94,98% hingga 95,77%.

CNN dapat mengungguli metode tradisional dalam melakukan segmentasi paru-paru pada citra CT-Scan dada[7]. Pada penelitian tersebut CNN diimplementasikan menggunakan arsitektur AlexNet dan algoritma klasterisasi tanpa supervisi dengan bahasa pemrograman MATLAB. Performa dari model tersebut dievaluasi menggunakan perhitungan *Dice Similarity Coefficient* (DSC) dan dibandingkan dengan hasil dari metode tradisional. CNN pada penelitian tersebut menunjukkan performa DSC dengan nilai 96,71% menungguli metode tradisional *Iteration*, *Improved Otsu*, *Watershed* dan *Region Growing*.

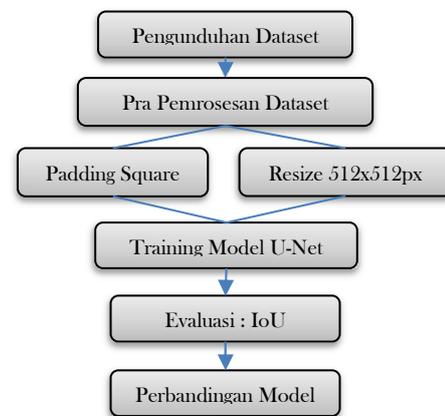
CNN pernah dicoba untuk diterapkan dalam segmentasi paru-paru dari citra *X-Ray* dada[8]. Pada penelitian tersebut CNN diterapkan menggunakan arsitektur AlexNet sebagai model utama di dalam klasifikasi piksel. Setiap piksel di dalam citra dikelaskan menjadi paru-paru atau bukan paru-paru. Metode yang diusulkan diterapkan menggunakan dataset dari Montgomery County (MC) dengan jumlah 138 citra *X-Ray* dada yang menghasilkan nilai akurasi 96,97% dan IoU 88,07%. Hasil dari segmentasi model tersebut masih perlu ditingkatkan menggunakan metode rekonstruksi agar batas area paru-paru lebih baik pada citra paru-paru yang tidak normal.

Sebagai tahapan yang sangat penting di dalam menegakkan diagnosa penyakit, segmentasi paru-paru menjadi bagian tidak terpisahkan di dalam pendeteksian penyakit Covid-19 yang menjadi pandemi sejak tahun 2019. CNN dengan arsitektur U-Net dapat melakukan segmentasi paru-paru dari irisan citra CT-Scan dada pasien terinfeksi Covid-19[9]. Penelitian tersebut menggunakan dataset CT-Scan dari pasien yang terinfeksi Covid-19. Arsitektur U-Net diterapkan dengan beberapa skenario yaitu U-Net asli dan U-Net dengan

pengurangan jumlah lapisan hingga tersisa 1 lapisan. Performa dari U-Net menunjukkan nilai 93,76% untuk tingkat akurasi pada U-Net asli dan 92,46% pada U-Net 1 layer.

### III. METODE PENELITIAN

Penelitian ini mencoba untuk melakukan pelatihan terhadap model segmentasi paru-paru menggunakan teknologi *Deep Learning* dengan arsitektur U-Net yang berupa jaringan konvolusi penuh. Untuk performa dari model yang dilatih akan dibandingkan dengan performa dari model atau metode segmentasi lain yang pernah dilakukan oleh peneliti lainnya.



Gambar 1. Bagan Alur Penelitian

#### A. Dataset

Untuk melatih model dalam mempelajari segmentasi batas dan area paru-paru diperlukan referensi atas batas dari paru-paru tersebut. Referensi yang baik didapatkan dari proses penggambaran batas oleh ahli radiologi, namun hal ini sulit didapatkan karena proses pembuatan anotasi yang cukup rumit dan lama, ahli radiologi harus melakukan pembuatan anotasi dengan melakukan klik sedikit demi sedikit menyusuri batas dari paru-paru pada setiap citra X-Ray dada yang tersedia[1].

Terdapat beberapa dataset citra X-Ray dada yang tersedia dan dapat diakses untuk diunduh secara publik[1]. Dataset yang pertama berasal dari *Japanese Society of Radiological Technology* (JSRT), dataset kedua berasal dari U.S. National Library of Medicine yang terdiri atas 2 dataset yaitu Montgomery County dan Shenzen, dataset ketiga berasal dari Belarus dan yang terakhir dari New Delhi. Dari

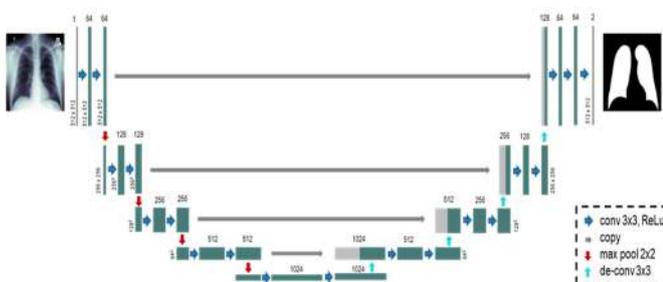
seluruh dataset yang disebutkan hanya dataset yang berasal dari Montgomery County (MC) dan JSRT yang menyediakan referensi anotasi batas paru-parunya.

Pada penelitian ini menggunakan dataset MC karena dataset tersebut yang memiliki pola deformasi paru-paru yang disebabkan oleh adanya penyakit tuberkulosis. Dataset MC juga memiliki referensi batas paru-paru yang digambarkan langsung oleh spesialis radiologi.

### B. Persiapan Model dan Arsitektur

Pelatihan model segmentasi memanfaatkan library yang telah tersedia secara publik. Model dibangun menggunakan bahasa pemrograman python dengan library yang digunakan untuk konvolusi adalah Keras dan Tensorflow. Tensorflow diperlukan agar model dapat mengaktifkan perangkat keras GPU sebagai perangkat utama dalam melakukan komputasinya. Perangkat GPU dapat lebih cepat di dalam melakukan metode Deep Learning, GPU memiliki kemampuan 4 hingga 5 kali lebih cepat dibandingkan dengan CPU[10].

Pada percobaan ini digunakan GPU RTX2060 dengan dikombinasikan CPU AMD Vishera fx-6300, memori ram DDR3 16 Gigabyte. Untuk persiapan perangkat lunak diperlukan instalasi pendukung tensorflow yaitu driver CUDA, Microsoft Visual Studio (bukan Visual Studio Code), NVidia CUDA Toolkit, cuDNN dengan versi yang sesuai untuk versi Tensorflow yang digunakan.



Gambar 2. Gambaran arsitektur U-Net

### C. Aktivasi

Dalam setiap satu langkah penuh arsitektur U-Net dilakukan aktivasi untuk ekstraksi fitur. Fungsi

aktivasi pada metode pembelajaran U-Net menggunakan ReLU.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$

Dimana x adalah nilai dari input.

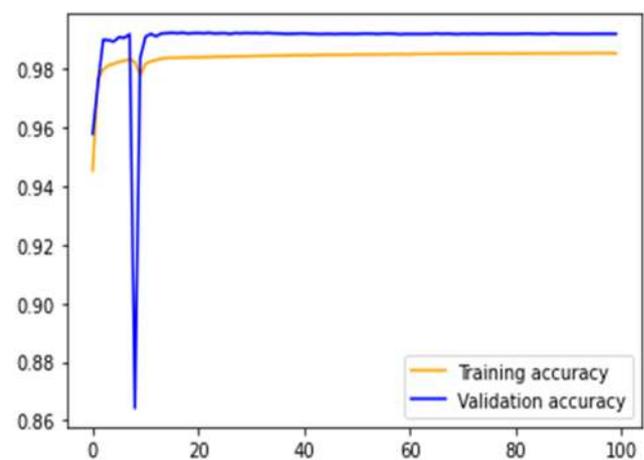
### D. Metode Evaluasi dan Pengujian

Untuk menghitung nilai performa dari model yang dilatih digunakan perhitungan yang telah dikenal secara luas di dalam bidang penelitian segmentasi citra medis [8]. Matrik evaluasi yang digunakan di dalam penelitian ini adalah akurasi dan *Jaccard Index* atau yang dikenal juga dengan *Intersection over Union* (IoU).

$$IoU = \frac{\text{area irisan}}{\text{area gabungan}} = \frac{\text{area irisan}}{\text{area gabungan}}$$

## IV. HASIL DAN PEMBAHASAN

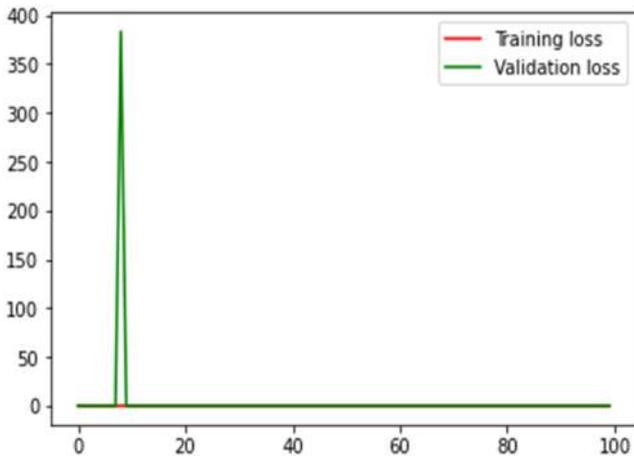
Percobaan untuk melatih model U-Net dilakukan dengan 100 epoch. Pada setiap akhir epoch dilakukan pengukuran fungsi loss, akurasi dan IoU. Dari seluruh epoch yang telah dilakukan didapatkan hasil pengukuran yang dapat dilihat pada grafik di dalam gambar 3, gambar 4 dan gambar 5.



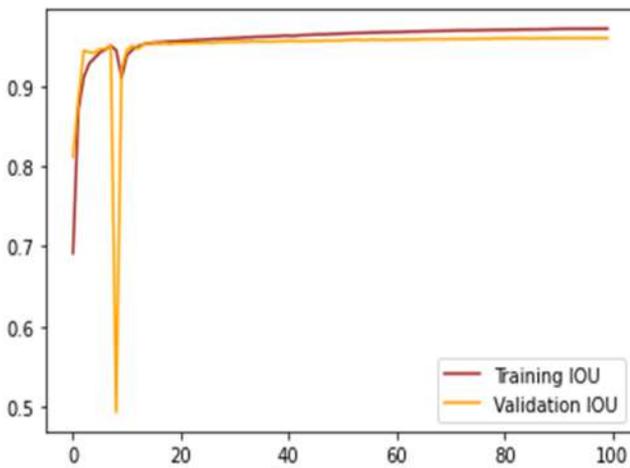
Gambar 3. Grafik akurasi model

Tingkat akurasi selama dilakukan pelatihan model dapat terlihat pada gambar 3 dengan garis berwarna kuning, sedangkan untuk akurasi validasi ditampilkan dengan garis berwarna biru. Terlihat akurasi saat validasi menurun tajam pada epoch ke-

8. Tingkat akurasi dari validasi tidak jauh berbeda dari akurasi dari training.



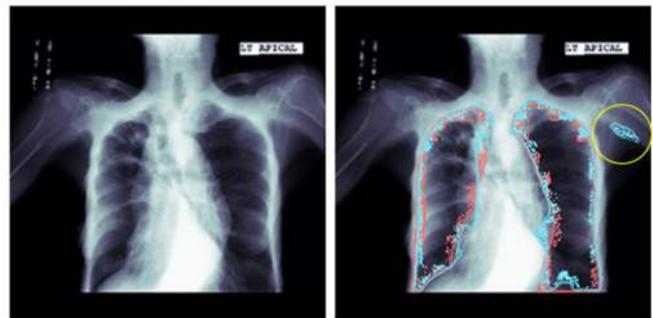
Gambar 4. Grafik fungsi loss



Gambar 5. Grafik IoU

Pada grafik fungsi loss terlihat antara training dan validasi cukup selaras hanya terjadi penurunan loss pada epoch ke-8 dimana pada epoch tersebut validasi akurasi juga berkurang. Pada grafik IoU juga demikian, angka IoU saat validasi menurun pada epoch ke-8.

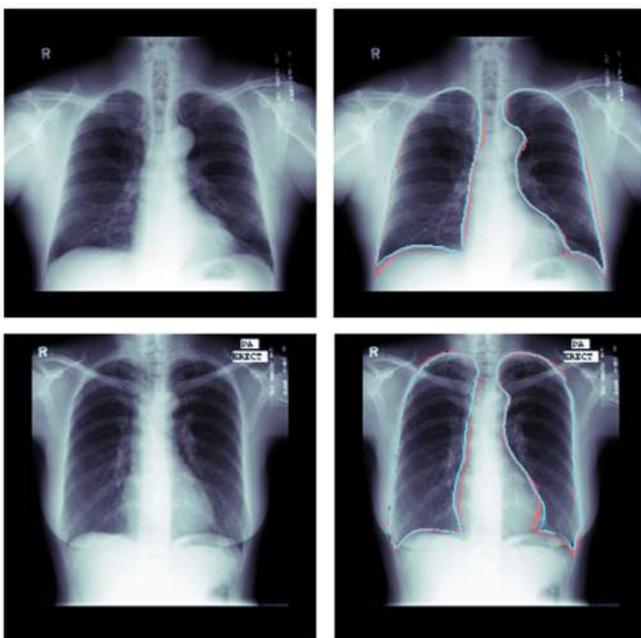
Dapat dilihat pada gambar hasil prediksi batas paru-paru bahwa garis berwarna biru merupakan hasil prediksi dari model setelah dilakukan pelatihan dan pengujian. Terlihat garis biru tidak terlalu jauh dari garis berwarna merah yang merupakan batas paru-paru *Ground Truth*. Secara visual terlihat hasil segmentasi paru-paru menunjukkan batas yang tegas dan jelas pada gambaran citra *X-Ray* dengan paru-paru normal.



— Ground Truth — Prediksi

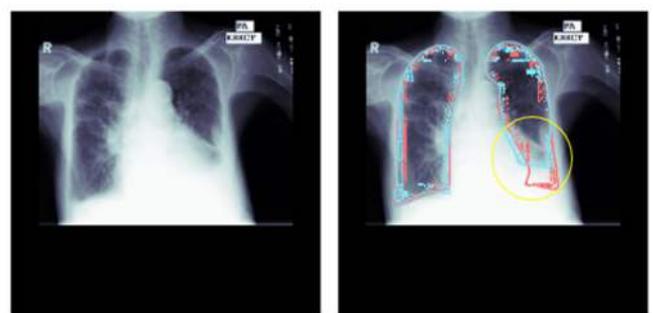
Gambar 7. Hasil dari prediksi batas paru-paru 2

Untuk hasil prediksi dari gambaran paru-paru dengan perubahan morfologi berhasil dilakukan namun terdapat beberapa bagian yang tidak tepat. Garis batas paru-paru prediksi tidak sepenuhnya rata sesuai dengan *Ground Truth*-nya dan masih terdapat sebuah area kecil di luar paru-paru yang terdeteksi sebagai salah prediksi paru-paru (lihat pada gambar dengan lingkaran kuning).



— Ground Truth — Prediksi

Gambar 6. Hasil dari prediksi batas paru-paru 1



— Ground Truth — Prediksi

Gambar 8. Hasil prediksi batas paru-paru berkabut

Tabel 1. Perbandingan Performa dengan Metode Sebelumnya

Metode	IoU	Akurasi	Dataset
SED [3]	94,6%	-	JSRT, CRASS
ED+Otsu [4]	91,5%	-	MC
AlexNet [8]	88,07%	96,97%	MC
U-Net	<b>95,46%</b>	<b>98,26%</b>	MC

Dapat dilihat pada tabel perbandingan performa antara metode segmentasi menggunakan DL dengan metode segmentasi menggunakan pengolahan citra konvensional. Metode segmentasi pada penelitian ini dapat menungguli performa dari metode pengolahan citra konvensional dan metode segmentasi menggunakan CNN AlexNet. Dengan dataset yang sama U-Net yang kami gunakan menunjukkan angka IoU 95,46% dan dapat mengungguli metode *Edge Detection + Otsu Thresholding* dengan angka IoU 91,5%. Dataset yang sama juga dicoba pada metode CNN AlexNet dengan nilai IoU 88,07% jauh di bawah metode U-Net yang kami gunakan.

Metode segmentasi menggunakan pengolahan citra konvensional tidak menunjukkan hasil akurasi karena tidak terdapat proses klasifikasi piksel pada metode tersebut. Akurasi hanya dapat diukur pada metode menggunakan CNN karena segmentasi pada CNN merupakan klasifikasi terhadap setiap piksel di dalam citra input. Akurasi dari metode U-Net yang digunakan dapat mengungguli metode CNN AlexNet dengan nilai 98,26% : 96,97%.

Pada metode yang diterapkan di dalam penelitian ini dapat menunjukkan bahwa model segmentasi menggunakan U-Net dapat dilatih hanya dengan jumlah dataset di bawah 100 gambar rontgen dada. Hal tersebut dapat menjadi solusi terhadap problem keterbatasan dataset pada bidang medis.

## V. KESIMPULAN

Segmentasi paru-paru pada citra X-Ray dada menggunakan metode Deep Learning menunjukkan kemampuan untuk dapat mengenali batas paru-paru pada X-Ray dada dengan gambaran paru-paru yang tidak normal. Hal tersebut menunjukkan keunggulan metode Deep Learning dibandingkan dengan metode pengolahan citra konvensional. Metode DL juga dapat mengungguli performa dari metode lain yang telah disebutkan dengan nilai akurasi 98,25% dan nilai IoU 94,55%.

Meskipun demikian di dalam melakukan pelatihan terhadap model DL diperlukan biaya perangkat yang lebih tinggi dibandingkan hanya menggunakan metode pengolahan citra sederhana. Selain itu masih terdapat kesalahan di dalam mengenali sebagian batas paru-paru dari citra X-Ray dengan gambaran paru-paru tidak normal, hal ini mungkin masih belum dapat sepenuhnya dijadikan pertimbangan dalam pengambilan tindakan medis secara otomatis.

Diharapkan pada penelitian selanjutnya dapat dilakukan percobaan untuk melakukan segmentasi paru-paru dari citra X-Ray dada dari hasil pemeriksaan pasien dengan posisi yang lain. Selain itu perlu dicoba untuk dapat menjadikan metode segmentasi tersebut dapat diintegrasikan dengan Sistem Informasi di Rumah Sakit sebagai sistem pendukung pemeriksaan penunjang di Instalasi Radiologi.

## DAFTAR PUSTAKA

- [1] S. Candemir and S. Antani, "A review on lung boundary detection in chest X-rays," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 14, no. 4, pp. 563–576, 2019, doi: 10.1007/s11548-019-01917-1.
- [2] M. N. Saad, Z. Muda, N. S. Ashaari, and H. A. Hamid, "Image segmentation for lung region in chest X-ray images using edge detection and morphology," *Proc. - 4th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2014*, no. September 2021, pp. 46–51, 2014, doi: 10.1109/ICCSCE.2014.7072687.
- [3] W. Yang *et al.*, "Lung Field Segmentation in Chest Radiographs From Boundary Maps by a Structured Edge Detector," *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 3, pp. 842–851, May 2018, doi: 10.1109/JBHI.2017.2687939.
- [4] A. Zotin, Y. Hamad, K. Simonov, and M. Kurako, "ScienceDirect ScienceDirect Lung boundary detection for chest X-ray images classification based Lung boundary detection for chest X-ray images classification based on GLCM and probabilistic neural networks on GLCM and probabilistic neural networks," *Procedia Comput. Sci.*, vol. 159, pp. 1439–1448, 2019, doi: 10.1016/j.procs.2019.09.314.
- [5] T. Agrawal and P. Choudhary, "Segmentation and classification on chest radiography: a systematic survey," *Vis. Comput.*, vol. 39, no. 3, pp. 875–913, 2023, doi: 10.1007/s00371-021-02352-7.
- [6] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9351, no. Cvd, pp. 12–20, 2015, doi: [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28).
- [7] M. Xu *et al.*, "Segmentation of lung parenchyma in CT images using CNN trained with the clustering

- algorithm generated dataset 08 Information and Computing Sciences 0801 Artificial Intelligence and Image Processing Robert Koprowski,” *Biomed. Eng. Online*, vol. 18, no. 1, pp. 1–22, 2019, doi: 10.1186/s12938-018-0619-9.
- [8] J. C. Souza, J. O. Bandeira Diniz, J. L. Ferreira, G. L. França da Silva, A. Corrêa Silva, and A. C. de Paiva, “An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks,” *Comput. Methods Programs Biomed.*, vol. 177, pp. 285–296, 2019, doi: 10.1016/j.cmpb.2019.06.005.
- [9] K. Asipong, S. Gabbualoy, and P. Phasukkit, “Coronavirus Infected Lung CT Scan Image Segmentation using Deep Learning,” *Smart Electr. Syst. Technol.*, 2021, [Online]. Available: <https://doi.org/10.1109/ECTI-CON51831.2021.9454944>
- [10] E. Buber and B. Diri, “Performance analysis and CPU vs GPU comparison for deep learning,” *2018 6th Int. Conf. Control Eng. Inf. Technol. CEIT 2018*, no. October, pp. 1–6, 2018, doi: 10.1109/CEIT.2018.8751930.