

## SEGMENTASI PARU-PARU PADA CITRA THORAX DADA DENGAN MENGGUNAKAN METODE CNN U-NET

Anisa Aulia Kusmareni<sup>1</sup>, Anita Desiani<sup>1</sup>, Sugandi Yahdin<sup>1</sup>, Mutiara Saviera<sup>1</sup>,

Ajeng Islamia Putri<sup>1</sup>, Des Alwine Zayanti<sup>1</sup>

<sup>1</sup>Program Studi Matematika, Universitas Sriwijaya, Sumatera Selatan.

e-mail: [08011281823031@student.unsri.ac.id](mailto:08011281823031@student.unsri.ac.id), [anita\\_desiani@unsri.ac.id](mailto:anita_desiani@unsri.ac.id), [sugandi@unsri.ac.id](mailto:sugandi@unsri.ac.id),

[08011181823001@student.unsri.ac.id](mailto:08011181823001@student.unsri.ac.id), [ajengip4@gmail.com](mailto:ajengip4@gmail.com), [desalwinez@unsri.ac.id](mailto:desalwinez@unsri.ac.id)

### *Abstrak*

Paru-paru merupakan salah satu organ terpenting dari tubuh manusia. Apabila terjadi keabnormalan pada kinerja paru-paru, akan dapat menimbulkan penyakit pernafasan yang dapat membuat tubuh tidak dapat menjalankan kinerjanya dengan normal. Untuk mendeteksi keabnormalan pada paru-paru, dapat dilakukan dengan melihat ukuran dari paru-paru tersebut. Maka dilakukan segmentasi pada citra thorax agar dapat mempermudah dalam mendeteksi keabnormalan tersebut. Penelitian ini menyajikan metode untuk segmentasi paru-paru pada foto thorax dada pasien dengan metode CNN U-Net. Pada langkah awal pada metode CNN U-Net dilakukan resize lalu segmentasi menggunakan keras optimizer Nadam. Didapatkan nilai rata-rata akurasi sebesar 0,9632, sensitifitas sebesar 0,9586, dan spesifisitas sebesar 0,9675, F1-Skor sebesar 0,9920, dan koefisien Jaccard sebesar 0,9842. Sehingga didapatkan bahwa dari penelitian ini, metode CNN U-Net sangat baik digunakan dalam implementasi segmentasi paru-paru pada citra thorax dada.

**Kata kunci:** Segmentasi, CNN, U-Net, Paru-paru

### *Abstract*

Lungs are one of the most important organs of the human body. If there is an abnormality in the performance of the lungs, it can cause respiratory disease that can make the body unable to perform its normal performance. To detect abnormalities in the lungs, it can be done by looking at the size of the lungs. Then the segmentation of the thorax image is carried out in order to make it easier to detect these abnormalities. This study presents a method for segmenting the lungs on chest radiographs of patients using the CNN U-Net method. In the initial step, the CNN U-Net method is resized and then segmented using the Nadam optimizer. The average value of accuracy is 0.9632, sensitivity is 0.9586, and specificity is 0.9675, F1-Score is 0.9920, and the Jaccard coefficient is 0.9842. Then it was found that from this study, the CNN U-Net method was very well used in the implementation of lung segmentation on chest thorax images.

**Keywords:** Segmentation, CNN, U-Net, Lung

## 1. PENDAHULUAN

Paru-paru merupakan salah satu organ yang berperan penting dalam menjalankan sistem respirasi (pernapasan). Saat udara mencapai paru-paru, akan terjadi pertukaran antara oksigen dari luar tubuh dengan karbon dioksida dari dalam darah. Jika paru-paru mengalami gangguan, maka proses ini pun akan ikut terganggu. Salah satu dari penyakit paru-paru adalah Tuberkulosis (TBC). TBC adalah penyakit paru-paru yang disebabkan oleh bakteri *Mycobacterium tuberculosis*. Bakteri ini tidak hanya menyerang paru-paru, tapi juga bisa menyebar ke bagian tubuh lain, seperti tulang, kelenjar getah bening, sistem saraf pusat, dan ginjal. Bakteri TBC menyebar di udara melalui percikan dahak atau cairan dari saluran pernapasan penderitanya, misalnya saat batuk atau bersin [1].

Untuk mendeteksi penyakit-penyakit yang disebabkan oleh kerusakan paru-paru dapat dilakukan dengan melakukan pemeriksaan radiologi foto thorax untuk menemukan apakah ada ketidaknormalan dari bentuk paru-paru dari pasien. Untuk melakukan hal

tersebut diperlukanlah segmentasi terhadap paru-paru agar dapat mendeteksi ketidaknormalan tersebut.

Pengolahan citra merupakan proses perbaikan citra dari berbagai gangguan (*noise*) sehingga mudah diinterpretasikan oleh manusia maupun mesin, citra tersebut dimanipulasi menghasilkan kualitas yang lebih baik. Proses pengolahan tersebut melibatkan input dan output dalam bentuk citra digital, perbedaan terdapat pada citra *output* yaitu lebih jelas dan memiliki kualitas yang lebih baik. Citra digital merupakan barisan bilangan nyata maupun kompleks yang diwakili oleh bit-bit tertentu. Citra digital berkaitan erat dengan warna oleh sebab itu umumnya pada penampilan visual, nilai data digital mendeskripsikan warna dari citra yang diolah. Bentuk citra digital yang dapat dipakai diantaranya citra biner, skala keabuan, warna dan warna [2].

Dalam melakukan pengolahan citra tersebut telah dapat dilakukan dengan melakukan segmentasi. Segmentasi itu sendiri merupakan sebuah proses pemisahan citra menjadi bagian-bagian yang diharapkan merupakan objek tersendiri atau membagi suatu citra menjadi wilayah-wilayah yang homogen berdasarkan kriteria keserupaan tertentu antara derajat keabuan suatu piksel dengan derajat keabuan piksel-piksel tetangganya [3]. Tujuan dari segmentasi itu sendiri adalah untuk mendapatkan fitur khusus pada citra tertentu yang sesuai dengan kebutuhan terhadap suatu citra [4].

Dengan kemajuan teknologi yang selalu berkembang seiring zaman, teknologi pada aplikasi yang memproses objek seperti pengenalan benda, rekonstruksi tiga dimensi, deteksi wajah, pengenalan tulisan, dan lainnya buat proses segmentasi semakin dibutuhkan [5]. Segmentasi dengan cara manual masih memungkinkan untuk dilakukan, namun prosedurnya dapat memakan waktu yang lebih dan juga membutuhkan operator yang khusus. Dan juga terjadinya varibilitas pada antar operator kemungkinan besar akan terjadi.

Sebelumnya, terdapat beberapa penelitian segmentasi paru-paru yang telah dilakukan dengan beberapa metode. Beberapa diantaranya adalah penelitian segmentasi paru-paru berdasarkan citra *x-ray* dengan menggunakan metode Chan-veze telah dilakukan oleh Hariadi [6] dari penelitian yang dilakukan pada 20 data citra *x-ray* thorax didapatkan hasil akurasi sebesar 87,89%, sensitifitas sebesar 76,27% dan spesifisitas sebesar 93,97%. Terdapat juga dari hasil penelitian lainnya yang dilakukan oleh Syaputri dan Zulkarnain [7] pada penelitian dengan menggunakan metode kontur aktif dengan validasi ROC didapatkan hasil akurasi sebesar 96,26%, spesifisitas sebesar 96,47% dan sensitifitas sebesar 76,54%. Dan selanjutnya juga telah dilakukan penelitian segmentasi paru-paru oleh Hartono [8] pada penelitian dengan menggunakan *K-Means* dan didapatkan hasil rata-rata akurasi sebesar 89,75%, nilai rata-rata sensitifitas 82,66% dan rata-rata spesifisitas sebesar 92,90%, selanjutnya penelitian [9] didapatkan akurasi 87,90%, sensitifitas 76,27%, dan spesifisitas 93,98% dengan metode *Distance Regularized Levelset Evolution* (DRLSE). Namun dari penelitian-penelitian tersebut hanya mencantumkan hasil akurasi, sensitifitas, dan spesifisitas. Pada penelitian ini akan mencantumkan *Dice similarity coefficient* (DSC) yang dapat mengukur seberapa kuat dan akuratnya arsitektur yang digunakan, dan *Jaccard similarity coefficient* (JSC) untuk mengevaluasi kinerja pada proses segmentasi yang dilakukan [10]. Dan selanjutnya pada penelitian [11] didapatkan akurasi sebesar 80% dengan menggunakan metode *Active Contour*.

Salah satu metode yang sedang berkembang saat ini dalam melakukan segmentasi adalah *Convolutional Neural Network* (CNN). CNN dapat mengenali pola dari input citra digital dan mengekstraksi fitur-fiturnya menggunakan kernel dan filter konvolusi [12].


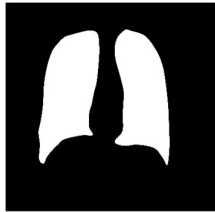

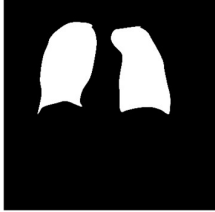




Salah satu arsitektur CNN yaitu U-Net. Kelebihan arsitektur U-Net adalah adanya fitur *skip connection* yang menyambungkan fitur tingkat rendah pada bagian *encoder* dan fitur tingkat tinggi pada bagian *decoder* [13]. Berdasarkan kelebihan CNN U-Net, maka pada penelitian ini dilakukan segmentasi pada *x-ray* thorax paru-paru menggunakan CNN U-Net dengan mengukur akurasi, sensitifitas, spesifisitas, DSC, dan JSC.


## 2. METODE PENELITIAN

### 2.1 Praproses Data

Dalam penelitian ini data diperoleh dari website *online* yaitu Kaggle dengan link <https://www.kaggle.com/nikhilpandey360/chest-xray-masks-and-labels>. Terdapat 800 gambar *x-ray* paru-paru. Dataset ini juga menyediakan hasil analisis ahli yang digunakan sebagai *ground truth* dalam penelitian untuk digunakan sebagai dasar pengujian keakuratan dan kinerja metode dalam program. Dataset yang digunakan dalam penelitian digunakan dengan 566 data dari dataset dengan jumlah yang memiliki *ground truth* sebanyak 138. Berikut pada Tabel 1. adalah contoh lima gambar dari keseluruhan dataset.

Tabel 1. Dataset dan *ground truth*


Nama	Dataset	Ground Truth
CHNCXR_0003_0		
CHNCXR_0029_0		
CHNCXR_0326_0		
CHNCXR_0447_1		



Tahap awal dari *preprocessing* menggunakan algoritma *resize* untuk menyamakan semua ukuran yaitu 512 x 512 x 1 dari dataset, dimana data-data pada dataset memiliki ukuran-ukuran bervariasi yang dapat menghambat jalannya segmentasi. Setelah itu dilanjutkan pada data yang telah di-*resize* tadi dilakukan proses segmentasi dengan metode U-Net menggunakan *Nadam Keras Optimizer*.

## 2.2. Metode CNN U-Net

U-Net adalah CNN yang dikembangkan untuk segmentasi gambar biomedis. Network dari U-Net berdasarkan dari *Convolutional Network* dan arsitekturnya dimodifikasi dan diperpanjang untuk menjalankan training yang lebih sedikit dengan menghasilkan segmentasi yang lebih tepat. Sedangkan CNN merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN merupakan sebuah algoritma pengembangan pada MLP dimana dirancang untuk mengolah data yang berbentuk *grid* seperti gambar ataupun suara yang merupakan citra dua dimensi. Pada Gambar 1. berikut ini adalah gambaran arsitektur U-Net yang digunakan pada penelitian ini :




Gambar 1. Arsitektur CNN U-Net

Dapat terlihat pada Gambar 1. bahwa pada arsitektur U-Net terdapat empat aktivitas, yaitu *Convolution Layer*, *Pooling Layer*, Aktivasi ReLu dan *Fully Connected Layer*.

### 2.2.1 Convolution Layer

Pada *Convolution Layer* dilakukan operasi konvolusi *output* pada lapisan sebelumnya. Konvolusi merupakan suatu istilah matematis yang dalam pengolahan citra yang berarti

mengaplikasikan sebuah kernel (kotak kuning) pada citra pada semua *offset* yang memungkinkan seperti pada Gambar 2., sedangkan kotak berwarna hijau secara keseluruhan merupakan citra yang akan dikonvolusi. Kernel (kotak kuning) bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut dapat dilihat pada gambar disebelah kanannya [14].



Gambar 2. Proses *Convolution Layer*


### 2.2.2 Pooling Layer

Selanjutnya adalah *Pooling Layer*. *Pooling Layer* adalah lapisan yang menggunakan fungsi dengan *Feature Map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat [15]. Adapun *Feature Map* dapat yang akan dihasilkan dari Persamaan 1. berikut ini.

$$n_{out} = \left( \frac{n_{in} - k + 2p}{s} \right) + 1 \quad (1)$$

Dimana  $n$  merupakan ukuran spasial dari gambar input,  $k$  merupakan ukuran spasial filter,  $p$  adalah jumlah penambahan angka yang berfungsi menyesuaikan gambar dimana umumnya adalah nol, dan  $s$  merupakan besaran dari setiap pergeseran filter pada proses komputasinya.

Setelah beberapa *layer*, *layer* ini disisipkan dengan teratur. *Pooling layer* dimasukkan diantara *convolution layer* dengan berturut-turut pada arsitektur CNN sehingga secara progresif dapat mengurangi ukuran volume *output* dari *feature map*. Sehingga didapatkan perhitungan dan jumlah parameter pada jaringan berkurang dan juga untuk mengendalikan *overfitting*. Bentuk terumum dari lapisan *Pooling* yaitu dengan menggunakan *filter* berukuran  $2 \times 2$  diaplikasikan dengan langkah sebanyak 2 lalu kemudian beroperasi pada setiap irisan dari *input*. Dari bentuk ini dapat mengurangi *Feature Map* hingga 75% dari ukuran volume *output* aslinya. Pada Gambar 3. ditunjukkan contoh operasi dari *Max Pooling*.



Gambar 3. Contoh Operasi *Max Pooling*

### 2.2.3 Aktivitas ReLU

Selanjutnya adalah Aktivasi ReLU (*Rectifier Linear Unit*). ReLU adalah fungsi aktivasi yang memiliki perhitungan dengan proses *forward* dan *backward* menggunakan kondisi *if*. Jika elemen bernilai negatif maka nilainya diset menjadi 0, tidak ada operasi

eksponensial, perkalian atau pembagian [16]. Persamaan 2. berikut adalah turunan dari fungsi aktivasi ReLU.

$$\frac{\partial y}{\partial x} = \begin{cases} 1 & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (2)$$

Dimana  $y$  merupakan matriks dari citra pada titik koordinat tertentu dan  $x$  merupakan hasil dari perhitungan tahap konvolusi.

#### 2.2.4 Fully Connected Layer

Dan selanjutnya adalah *Fully Connected Layer* dimana biasanya digunakan dengan tujuan melakukan transformasi pada dimensi dari sebuah data agar data tersebut dapat diklasifikasikan secara liner. Setiap *neuron* pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah *fully connected layer*. Karena hal tersebut menyebabkan data kehilangan informasi spesialnya dan tidak *reversible*, *fully connected layer* hanya dapat diimplementasikan di akhir jaringan [17]. *Fully connected layer* terdiri dari tiga yaitu *input layer*, *hidden layer*, dan *output layer*.

*Input Layer* adalah penggabungan dari keseluruhan matriks *feature map* yang didapatkan dari proses *pooling layer* dimana selanjutnya seluruh piksel direntangkan menjadi sebuah vektor pada sepanjang jumlah piksel dari matriks yang didapatkan dari *pooling layer*. Lalu seluruh nilai dari *input layer* akan digunakan pada perhitungan *hidden layer* [18].

Pada perhitungan *hidden layer* dilakukan dengan mengkalikan keseluruhan nilai dari *input layer* dengan bobot yang telah diinisialisasikan sebelumnya yang selanjutnya ditambahkan dengan nilai bias. Pada Persamaan 3. berikut adalah persamaan perhitungannya.

$$z_{in} = \sum_{j=1}^n X_j * V_{j,i} + V_{0,i} \quad (3)$$

Dimana  $z_{in}$  merupakan masukan untuk node dari *hidden layer* ke- $i$  dengan jumlah node ke  $n$ ,  $X_j$  merupakan node  $X$  ke- $j$ ,  $V_{j,i}$  merupakan bobot  $V$  untuk  $X_j$  dan node  $Z_i$ , dan  $V_{0,i}$  merupakan bias  $V$  untuk  $z_{in}$ .

Selanjutnya setelah perhitungan dimasukkan fungsi aktivasi ReLU pada semua hasil perhitungan yang telah dilakukan, maka diperoleh nilai keluaran  $Z$ . dan hasil dari perhitungan tersebut digunakan pada proses perhitungan *output layer* dimana perhitungannya mengkalikan nilai-nilai hasil perhitungan dari *hidden layer*. Persamaan 4. berikut merupakan persamaan perhitungannya.

$$y_{in_i} = \sum_{j=1}^m Z_j * W_{j,i} + W_{0,i} \quad (4)$$

Dimana  $y_{in_i}$  merupakan masukan untuk node *hidden layer*  $Z$  ke- $i$  dengan jumlah node  $m$ ,  $Z_j$  merupakan node  $Z$  ke- $j$ ,  $W_{j,i}$  merupakan bobot  $W$  untuk  $Z_j$  dan node  $Y_i$ , dan  $W_0$  untuk bisa  $W$  pada  $y_{in_i}$ .

#### 2.2.5 Aktivasi Sigmoid

Aktivasi sigmoid atau juga disebut fungsi aktivasi logistik adalah sebuah fungsi yang menerima angka tunggal dan mengubah nilai  $x$  menjadi sebuah nilai yang memiliki *range* mulai dari 0 sampai 1 [19]. Persamaan 5. berikut adalah fungsi aktivasi sigmoid.


$$S(x) = \frac{1}{1+e^{-x}} \quad (5)$$

Pada persamaan 6. menunjukkan turunan dari fungsi aktivasi sigmoid.


$$\frac{\partial x}{\partial y} = \frac{1}{1+e^{-x}} \times \left(1 - \frac{1}{1+e^{-x}}\right) \quad (6)$$

### 3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan menggunakan dataset dengan rasio *training* dan *validation* sebesar 80:20. Algoritma U-Net yang akan diujikan, terdapat *hyperparameter* dan parameter pada fungsi optimasi *Nadam Optimizer*. Nilai dari *hyperparameter* adalah *learning rate* ( $lr$ ) = 0,00001, *batch size* = 16, dan *epoch* = 15. Berikut pada Gambar 4. dan Gambar 5. merupakan grafik perbandingan *Loss Fase* dan Akurasi dari *training* pada dataset dengan *epoch* berjumlah 15.



Gambar 4. Grafik Perbandingan *Loss Fase Training* dan Validasi pada proses segmentasi Paru-paru



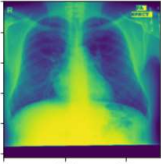

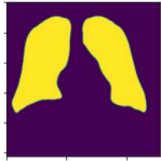
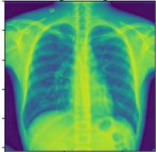
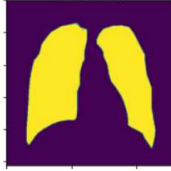
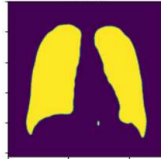
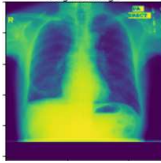
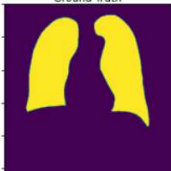
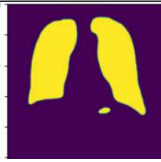
Gambar 5. Grafik Perbandingan Akurasi Fase *Training* dan Validasi pada proses segmentasi Paru-paru

Pada Gambar 4. & Gambar 5. didapatkan bahwa grafik menuju konvergen, tidak menunjukkan kondisi *overfitting* ataupun *underfitting*. *Overfitting* itu sendiri adalah

ketika model yang terlalu dibuat fokus pada *training* dataset tertentu, sehingga tidak dapat melakukan prediksi dengan benar apabila diberikan dataset yang serupa. Sedangkan *Underfitting* adalah ketika model yang telah dibentuk tidak mampu melihat logika dibalik dataset sehingga tidak dapat melakukan prediksi dengan hasil akurat baik pada data *training* maupun *validation* [20]. Dari grafik tersebut didapatkan dari hasil segmentasi paru-paru dengan *epoch* 15 akurasi sebesar 96,44% dan *loss* sebesar -0,9537.

Setelah dilakukan *training*, dilanjutkan dengan proses segmentasi. Berikut pada Tabel 2. merupakan perbandingan hasil dari segmentasi, dengan gambar citra beserta dengan *ground truth* dari dataset tersebut.

Tabel 2. Hasil Segmentasi

Gambar Citra	Ground Truth	Hasil Segmentasi
		
		
		

Dari Tabel 2. diatas, dapat terlihat bahwa hasil dari segmentasi sangat mirip dengan *ground truth* dari citra. Selanjutnya agar dapat menghitung akurasi dari hasil segmentasi tersebut, beberapa parameter klasifikasi sedang dipertimbangkan dan dihitung, yaitu *True Negative* (TN), *True Positive* (TP), *False Negatif* (FN) dan *False Positive* (FP). Setelah itu, parameter yang terlibat untuk mengukur kinerja pendekatan yang diusulkan berdasarkan akurasi, sensitivitas, spesifisitas, *Dice similarity coefficient*, dan *Jaccard similarity coefficient*. Dan setelah dilakukan segmentasi, didapatkan nilai *True Negative* (TN) sebesar 3.218.892, *True Positive* (TP) sebesar 3.218.892, *False Negatif* (FN) sebesar 131.841 dan *False Positive* (FP) sebesar 107.818. Dari nilai-nilai tersebut didapatkan nilai hasil seperti pada Tabel 3. berikut:

Tabel 3. Nilai Hasil dari Penelitian

Akurasi	0,9632042215678267
Sensitifitas	0,9586252671417946
Spesifisitas	0,9675902017308392
DSC	0,962252462869332
JSC	0,9842378129516875



Setelah didapatkan hasil dari penelitian menggunakan metode CNN U-Net maka apabila dibandingkan dengan penelitian yang telah dilakukan sebelumnya seperti pada Tabel 4. berikut :

Tabel 4. Perbandingan Nilai Hasil

Metode	Akurasi	Sensitifitas	Spesifisitas	DSC	JSC
U-Net CNN	0,9632	0,9586	0,9675	0,9622	0,9842
Chan-veese [6]	0,8789	0,7627	0,9397	-	-
Kontur aktif dengan validasi ROC [7]	0,9624	0,7654	0,9647	-	-
K-Means [8]	0,8975	0,8266	0,9290	-	-
Distance Regularized Levelset Evolution (DRLSE) [9]	0,8790	0,7627	0,9398	-	-
Active Contour [11]	0,8000	-	-	-	-

Dari Tabel 4., dapat terlihat bahwa hasil dari segmentasi paru-paru dengan menggunakan metode U-Net mendapatkan nilai akurasi, sensitifitas, spesifisitas, DSC, dan JSC yang lebih tinggi dibandingkan dengan metode lain yang telah diujikan sebelumnya.

#### 4. KESIMPULAN

Berdasarkan hasil dari penelitian yang telah dilakukan, didapatkan bahwa implementasi arsitektur U-Net pada segmentasi paru-paru citra thorax dada diperoleh hasil yang sangat baik dengan nilai akurasi sebesar 96,32%, sensitifitas sebesar 95,86%, spesifisitas sebesar 96,75%, DSC sebesar 96,22% dan JSC sebesar 98,42%. Hal ini menunjukkan bahwa kelebihan dari arsitektur U-Net mampu memprediksi piksel dengan baik pada paru-paru dan *background* dari citra thorax dada yang dimasukkan pada proses segmentasi sehingga mendapatkan hasil yang sangat baik.

Dalam penelitian ini dibatasi hanya melakukan proses segmentasi paru-paru dengan menggunakan arsitektur U-Net. Diharapkan untuk penelitian yang akan datang dapat dilakukan proses klasifikasi keabnormalan pada paru-paru.

#### DAFTAR PUSTAKA

- [1] S. Hardiyanti, "Karakteristik Pasien Tb Paru Berdasarkan Pemeriksaan Foto Thorax Di Bagian Radiologi Rsup Dr . Wahidin Sudirohusodo Makassar Rsup Dr . Wahidin Sudirohusodo Makassar Periode Juni 2016-Juni 2017," *Skripsi Fak. Kedokt. Univ. Hasanuddin Makasar*, no. November, 2017.
- [2] S. Bhahri and Rachmat, "Transformasi Citra Biner Menggunakan," *J. Sist. Inf. dan Teknol. Inf.*, vol. 7, no. 2, pp. 195–203, 2018.
- [3] A. Bali and S. N. Singh, "A review on the strategies and techniques of image segmentation," *Int. Conf. Adv. Comput. Commun. Technol. ACCT*, vol. 2015-April, pp. 113–120, 2015, doi: 10.1109/ACCT.2015.63.
- [4] A. Desiani, D. A. Zayanti, R. Primartha, F. Efriliyanti, and N. A. C. Andriani, "Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina," *J.*

- Edukasi dan Penelit. Inform.*, vol. 7, no. 2, p. 255, 2021, doi: 10.26418/jp.v7i2.47205.
- [5] L. Angriani, "Segmentasi Citra dengan Metode Threshold pada Citra Digital Tanaman Penyelenggara : Program Studi Teknik Informatika Fakultas Ilmu Komputer Universitas Muslim Indonesia Makassar , Indonesia Editor : Tim Editor SNRIK 2015 Penerbit : Fakultas Ilmu Komputer," *Semin. Nas. Ris. Ilmu Komput.*, vol. 1, no. 2, 2015.
- [6] M. A. Hariadi, "Aplikasi Segmentasi Paru - Paru," *Matics*, vol. 7, no. 1, p. 5, 2015, doi: 10.18860/mat.v7i1.2870.
- [7] S. Syaputri and Z. Zulkarnain, "Segmentasi Citra Paru-Paru Menggunakan Metode Kontur Aktif Dengan Validasi Roc," *Komun. Fis. Indones.*, vol. 16, no. 2, p. 91, 2019, doi: 10.31258/jkfi.16.2.91-95.
- [8] W. Hartono, "Segmentasi Paru-paru pada Citra X-ray Thorax Menggunakan K-Means," *UIN Maulana Malik Ibrahim Malang*, 2017.
- [9] M. A. Hariyadi, "Segmentasi Paru-Paru pada Citra X-Ray Thorax Menggunakan Distance Regularized Levelset Evolution (DRLSE)," *Matics*, vol. 9, no. 1, p. 48, 2017, doi: 10.18860/mat.v9i1.4130.
- [10] B. Oltu, B. K. Karaca, H. Erdem, and A. Özgür, "A systematic review of transfer learning based approaches for diabetic retinopathy detection," 2021.
- [11] N. Fadillah and C. R. Gunawan, "Segmentasi Citra Ct Scan Paru-Paru Dengan Menggunakan Metode Active Contour," *JURIKOM (Jurnal Ris. Komputer)*, vol. 6, no. 2, pp. 126–132, 2019.
- [12] R. Chauhan, K. K. Ghanshala, and R. C. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition," *ICSCCC 2018 - 1st Int. Conf. Secur. Cyber Comput. Commun.*, no. February, pp. 278–282, 2018, doi: 10.1109/ICSCCC.2018.8703316.
- [13] S. T. Tran, C. H. Cheng, T. T. Nguyen, M. H. Le, and D. G. Liu, "Tmd-unet: Triple-unet with multi-scale input features and dense skip connection for medical image segmentation," *Healthc.*, vol. 9, no. 1, pp. 1–19, 2021, doi: 10.3390/healthcare9010054.
- [14] T. F. Kusumaningrum, "IMPLEMENTASI CONVOLUTION NEURAL NETWORK (CNN) UNTUK KLASIFIKASI JAMUR KONSUMSI DI INDONESIA MENGGUNAKAN KERAS," *Adv. Opt. Mater.*, vol. 10, no. 1, pp. 1–9, 2018.
- [15] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.
- [16] M. Satria Wibawa, "Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan," *J. Sist. Dan Inform.*, vol. 11, no. December, 2016, doi: 10.13140/RG.2.2.21139.94241.
- [17] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [18] A. Hibatullah and I. Maliki, "Penerapan Metode Convolutional Neural Network Pada Pengenalan Pola Citra Sandi Rumput," 2019.
- [19] A. C. Sitepu and M. Sigiro, "Analisis Fungsi Aktivasi Relu dan Sigmoid menggunakan optimizer SGD dengan Representasi MSE pada Model

- Backpropogation,” *Pros. SeNTIK*, vol. 1, pp. 12–25, 2021.
- [20] I. Bagus, L. Mahadya, M. Sudarma, I. N. S. Kumara, and A. Optimizer, “Resonance Imaging dengan Menggunakan Metode U-NET,” *Maj. Ilm. Teknol. Elektro*, vol. 19, no. 2, pp. 151–156, 2020.