

SEGMENTASI CITRA X-RAY DADA MENGGUNAKAN METODE MODIFIKASI DEEPLABV3+

Rima Tri Wahyuningrum^{*1}, Maughfirotul Jannah², Budi Dwi Satoto³, Amillia Kartika Sari⁴, Anggraini Dwi Sensusiati⁵

^{1,2,3}Universitas Trunojoyo Madura, Kabupaten Bangkalan, ^{4,5}Universitas Airlangga, Surabaya
Email: ^{*}rimatriwahyuningrum@trunojoyo.ac.id, ²maughfirotuljannah911@gmail.com,
³budids@trunojoyo.ac.id, ⁴amillia.kartika.sari@vokasi.unair.ac.id, ⁵anggraini-d-s@fk.unair.ac.id
^{*}Penulis Korespondensi

(Naskah masuk: 07 Desember 2022, diterima untuk diterbitkan: 21 Juni 2023)

Abstrak

COVID-19 merupakan penyakit yang mengganggu sistem pernapasan manusia. Perkembangan terbaru September 2022 jumlah kasus COVID-19 di seluruh dunia terkonfirmasi mencapai 608.328.548 dengan pasien yang meninggal berjumlah 6.501.469. Sedangkan di Indonesia yang terkonfirmasi COVID-19 mencapai 6.408.806 dengan pasien yang meninggal sebanyak 157.892. *Reverse Transcription Polymerase Chain Reaction* (RT-PCR) merupakan alat yang paling banyak digunakan untuk mendeteksi COVID-19. Namun, laporan terakhir uji RT-PCR menunjukkan bahwa uji RT-PCR tersebut kurang memadai. Sebagai alternatifnya, citra radiografi seperti *x-ray* dan CT-Scan dada dapat membantu dalam mendeteksi penyakit ini. Citra radiografi khususnya *x-ray* perlu dilakukan pengolahan untuk dapat melakukan diagnosis. *Computer Aided Diagnosis* (CAD) adalah sistem diagnosis berbantuan komputer yang bisa digunakan sebagai informasi pendukung dalam melakukan diagnosis. Untuk mempermudah dalam melakukan diagnosis diperlukan suatu model *deep learning* yang dapat membantu hal tersebut. *DeepLabV3+* merupakan salah satu metode yang dapat melakukan proses segmentasi. *DeepLabV3+* merupakan perluasan pada *DeepLabV3* dengan tujuan supaya bisa menyempurnakan hasil segmentasi. *DeepLabV3+* menggunakan *Xception* yang dimodifikasi sebagai *backbone*. Dalam penelitian ini menggunakan 1.500 data citra *x-ray* dada yang kemudian data tersebut dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian. Terdapat 4 skenario uji coba dalam penelitian ini yaitu dengan *learning rate* 0,01 tanpa CLAHE, *learning rate* 0,01 dan menggunakan CLAHE, *learning rate* 0,0001 tanpa CLAHE, serta *learning rate* 0,0001 menggunakan CLAHE. Dari 4 skenario tersebut skenario *learning rate* 0,01 dan menggunakan CLAHE mendapatkan hasil evaluasi tertinggi dengan menggunakan *Dice Similarity Coefficient* (DSC) sebesar 96,91%.

Kata kunci: Segmentasi Citra, *x-ray* dada, CLAHE, *DeepLabV3+*

CHEST X-RAY IMAGE SEGMENTATION USING DEEPLABV3+ METHOD

Abstract

COVID-19 is a disease that affects the human respiratory system. The latest developments in September 2022 the number of confirmed cases of COVID-19 worldwide reached 608,328,548 with 6,501,469 patients who died. While in Indonesia confirmed COVID-19 reached 6,408,806 with 157,892 patients who died. *Reverse Transcription Polymerase Chain Reaction* (RT-PCR) is the most widely used tool. However, the latest RT-PCR test report shows that the RT-PCR test is inadequate. As an alternative, radiographic images such as chest x-rays and CT scans can help detect this. Radiographic images, especially x-rays, need processing to be able to make a diagnosis. *Computer Aided Diagnosis* (CAD) is a computer assisted diagnosis system that can be used as supporting information in making a diagnosis. To make it easier to make a diagnosis, we need a deep learning model that can help with this. *DeepLabV3+* is a method that can carry out the segmentation process. *DeepLabV3+* which is an extension of *DeepLabV3* with the aim of improving the segmentation results. *DeepLabV3+* uses a modified *Xception* as the backbone. In this study, 1,500 chest x-ray image data were used which were then divided into 80% for training data and 20% for testing data. There are 4 test scenarios in this study, namely with a learning rate of 0,01 without CLAHE, a learning rate of 0,01 and using CLAHE, a learning rate of 0,0001 without CLAHE, and a learning rate of 0,0001 using CLAHE. Of the 4 scenarios the learning rate scenario is 0,01 and using CLAHE gets the highest evaluation results using the *Dice Similarity Coefficient* (DSC) of 96,91%.

Keywords: Image Segmentation, chest x-ray, CLAHE, *DeepLabV3*

1. PENDAHULUAN

COVID-19 merupakan penyakit yang mengganggu sistem pernapasan pada manusia (El-BANA et al., 2020). Virus *Severe Acute Respiratory Syndrome Coronavirus-2* (SARS-CoV-2) adalah penyebab penyakit ini (El-Bana et al., 2020; Rothan and Byrareddy, 2020; Shi et al., 2021; Susilo et al., 2020; Yan et al., 2020). Awalnya COVID-19 diberi nama *2019 novel coronavirus* (2019-nCoV). Kemudian diganti menjadi *Coronavirus Disease* (COVID-19) pada tanggal 11 Februari 2020 oleh WHO (Rothan and Byrareddy, 2020; Susilo et al., 2020).

COVID-19 menyebar dengan sangat pesat sehingga mempengaruhi berbagai negara di seluruh dunia termasuk Indonesia (Rothan and Byrareddy, 2020; Susilo et al., 2020; Yan et al., 2020). Pada akhir Januari 2020, WHO atau *World Health Organization* menyatakan bahwa COVID-19 sebagai darurat kesehatan global (Shi et al., 2021; Yan et al., 2020). Dan pada tanggal 11 Maret 2020 sebagai pandemi (El-Bana et al., 2020; Shi et al., 2021). Pada tanggal 18 September 2022, WHO telah melaporkan 609.095.968 kasus yang terkonfirmasi COVID-19 termasuk 6.505.455 yang mengalami kasus kematian (Who, 2022). Hal tersebut mendorong pemerintah untuk melakukan upaya pencegahan salah satunya dengan mempersiapkan alat untuk mendiagnosa apakah warga terpapar virus atau tidak.

Nucleic Acid Test merupakan alat yang paling banyak digunakan, khususnya *Polymerase Chain Reaction* (PCR), seperti *Reverse Transcription Polymerase Chain Reaction* (RT-PCR) (El-Bana et al., 2020; Yudistira et al., 2020). Namun, laporan terbaru uji RT-PCR menunjukkan bahwa uji RT-PCR kurang memadai dalam mendeteksi COVID-19. Hal tersebut disebabkan oleh beberapa faktor seperti persiapan sampel dan kualitas kontrol (El-Bana et al., 2020; Shi et al., 2021; Yan et al., 2020). Sebagai alternatifnya, citra radiologi seperti *x-ray* dan CT-Scan dapat membantu dalam mendeteksi paru-paru yang terkena COVID-19 (Yudistira et al., 2020). Alat ini lebih mudah digunakan dibandingkan dengan RT-PCR serta memiliki sensitivitas yang tinggi untuk *skrining* infeksi COVID-19 (Yan et al., 2020).

Pengelolaan citra radiografi sangat penting karena hal tersebut berisi informasi yang dapat mendukung dalam melakukan diagnosis. Selain itu, dengan adanya perkembangan kecerdasan buatan yang sangat pesat dapat dimanfaatkan untuk mengurangi dampak kekurangan alat uji RT-PCR dan membantu meminimalkan biaya dan waktu pengujian (Yudistira et al., 2020).

Deep Learning (DL) merupakan suatu bagian dari pembelajaran mesin (*Machine Learning*) yang berbasis jaringan saraf tiruan yang dapat mempelajari metode komputasinya sendiri (Nugroho et al., 2020). *Deep Learning* banyak digunakan dalam pengenalan citra karena memiliki tingkat keakuratan yang lebih tinggi (Hasma and Silfianti, 2018).

Selain itu dibutuhkan juga *preprocessing* data dengan menggunakan *Contrast Limited Adaptive Histogram* (CLAHE). Hal tersebut dimaksudkan supaya dapat melakukan segmentasi terhadap citra *x-ray* dada dengan lebih baik dan meningkatkan hasil evaluasi model.

Terkait beberapa penelitian sebelumnya tentang segmentasi citra yaitu pada tahun 2020, Cheng et al. mampu mengimplementasikan model *Deep Learning* berupa *Fully Convolutional Attention Network* (FCANet). Modul *attention* terdiri dari *spatial attention* dan *channel attention* yang ditambahkan pada *encoder* Res2Net sehingga mampu merepresentasikan fitur secara lebih baik. Penelitian ini memanfaatkan 3 buah *dataset open source* yaitu data *x-ray* dada dari *Chest X-Ray Collection* sebanyak 138 citra, data citra nukleus dari Kaggle 2018 Data Science Bowl sebanyak 660 citra dan data citra kanker serviks dari Herlev dataset sebanyak 917 citra. Hasil evaluasi model ini menunjukkan bahwa FCA-Net mampu memperoleh rata-rata nilai DSC sebesar 98,32% (Cheng et al., 2020).

Pada tahun 2021, Saood et al. melakukan penelitian segmentasi data CT paru-paru COVID-19 menggunakan *U-Net* versus *Segnet* (Saood and Hatem, 2021). Pada penelitian ini menggunakan *dataset* dari *Italian Society of Medical and Interventional Radiology*, dimana sudah disediakan dalam ukuran 512 x 512. Hasil segmentasi biner pada semua percobaan menghasilkan nilai akurasi lebih besar dari 0,90. Untuk arsitektur *SegNet* nilai akurasi terbaik yaitu 0,954 pada percobaan 4 sedangkan untuk arsitektur *U-Net* nilai akurasi terbaiknya yaitu 0,95 pada percobaan 4. Sementara itu hasil segmentasi *multi-class*, percobaan terbaik dari arsitektur *SegNet* yaitu pada percobaan 7 dengan hasil akurasi 0,907. Sedangkan untuk arsitektur *U-Net*, percobaan terbaiknya yaitu pada percobaan 4 dengan hasil akurasi 0,908.

Pada tahun 2020, Muller et al. melakukan penelitian segmentasi CT-Scan dada otomatis dari infeksi Paru-Paru COVID-19 menggunakan *U-Net* 3D Standar (Muller et al., 2020). *Dataset* berupa *dataset public* yang disediakan oleh Ma et al., terdiri dari 20 volume CT-Scan dada COVID-19 beranotasi. Penelitian ini menghasilkan model validasi silang mencapai *Dice Similarity Coefficient* (DSC) sekitar 0,956 untuk segmentasi paru-paru dan 0,761 untuk infeksi COVID-19. Sedangkan untuk sensitivitas dan spesifisitas mencapai 0,956 dan 0,998 untuk paru-paru, serta 0,730 dan 0,999 untuk infeksi.

DeepLab memiliki beberapa variasi diantaranya *DeepLabV1*, *DeepLabV2*, *DeepLabV3*, dan *DeepLabV3+*. *DeepLabV1* sudah berhasil melakukan pengurangan resolusi fitur dan akurasi pelokalan berkurang karena invariant DCNN (Chen et al., 2014), tetapi masih memiliki kekurangan yang terletak pada keberadaan objek di berbagai skala. Kemudian, *DeepLabV2* mengatasi kekurangan tersebut dengan menggunakan *Atrous Spatial*

Pyramid Pooling (ASPP) (Chen, Papandreou, et al., 2018). Namun dalam menangkap batas objek belum tajam sehingga dikembangkan *DeepLabV3*. *DeepLabV3* bisa menangkap batas objek yang tajam namun belum sempurna (Chen et al., 2017).


Selanjutnya, *DeepLabV3+* yang merupakan perluasan dari *DeepLabV3* dengan menambahkan modul *decoder* sederhana namun efektif untuk menyempurnakan hasil segmentasi terutama sepanjang batas objek (Chen, Zhu, et al., 2018).

Selain itu, *DeepLabV3+* telah diimplementasikan pada beberapa dataset citra radiologi baik CT-Scan maupun X-ray dada (El-Bana et al., 2020). Namun, pada penelitian ini mengusulkan modifikasi *DeepLabV3+* ini. Yaitu dengan menambahkan skip koneksi kedua pada *backbone Aligned Xception*, yang disebut *Modified Aligned Xception*. Untuk menguji keakuratan hasil segmentasi dari model *DeepLabV3+*, pada penelitian ini melakukan beberapa skenario uji coba dan perhitungan performa model menggunakan *Dice Similarity Coefficient* (DSC).

2. KAJIAN PUSTAKA

2.1 Citra

Citra digital merupakan fungsi dari intensitas cahaya yang digambarkan dalam bidang dua dimensi yang berbentuk matrik berukuran $M \times N$. Dimana M menyatakan baris dan N menyatakan kolom (Susanto, 2019). Gambar 1 merupakan ilustrasi dari sistem koordinat citra digital.



Gambar 1 Sistem Koordinat Citra Digital

Selanjutnya, persamaan 1 merupakan bentuk matrik dari citra digital yang menunjukkan letak sebuah piksel.

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (1)$$

Dimana:

- $f(x,y)$: Fungsi dua dimensi
- f : Nilai intensitas
- x : Koordinat spasial
- y : Koordinat spasial
- M : Tinggi citra
- N : Lebar citra

Kedua ruas dari persamaan 1 adalah sebuah ekuivalen yang menyatakan sebuah citra digital. Pada bagian kanan dari persamaan 1 merupakan bilangan ril dari sebuah matrik. Setiap elemen pada matriks citra disebut *image element* atau piksel (Susanto, 2019).

2.2 Segmentasi Citra

Segmentasi merupakan proses pemisahan citra antara objek yang diinginkan (*foreground*) dengan latar belakang (*background*) (Kumaseh et al., 2013). Segmentasi citra digunakan untuk mempartisi citra menjadi bagian yang memiliki ciri yang serupa. Tujuan utama dari segmentasi citra yaitu untuk mempermudah dalam melakukan analisis (Kaur and Kaur, 2014).

2.3 Contrast Limited Adaptive Histogram Equalization (CLAHE)

CLAHE merupakan metode untuk meningkatkan detail kecil, dan kontras dari sebuah citra. CLAHE mampu menghasilkan citra yang lebih baik dari citra asli yang belum dilakukan *preprocessing*. CLAHE menunjukkan keberhasilannya dalam peningkatan citra medis dengan kontras rendah dan dapat mengatasi kekurangan *Adaptive Histogram Equalization* (AHE) dengan memberikan nilai batas pada histogram. *Clip limit* merupakan nilai batas yang diberikan dengan tujuan agar dalam peningkatan kontras tidak over (Baso and Suciati, 2020). Rumus untuk menghitung *clip limit* terdapat pada persamaan 2:

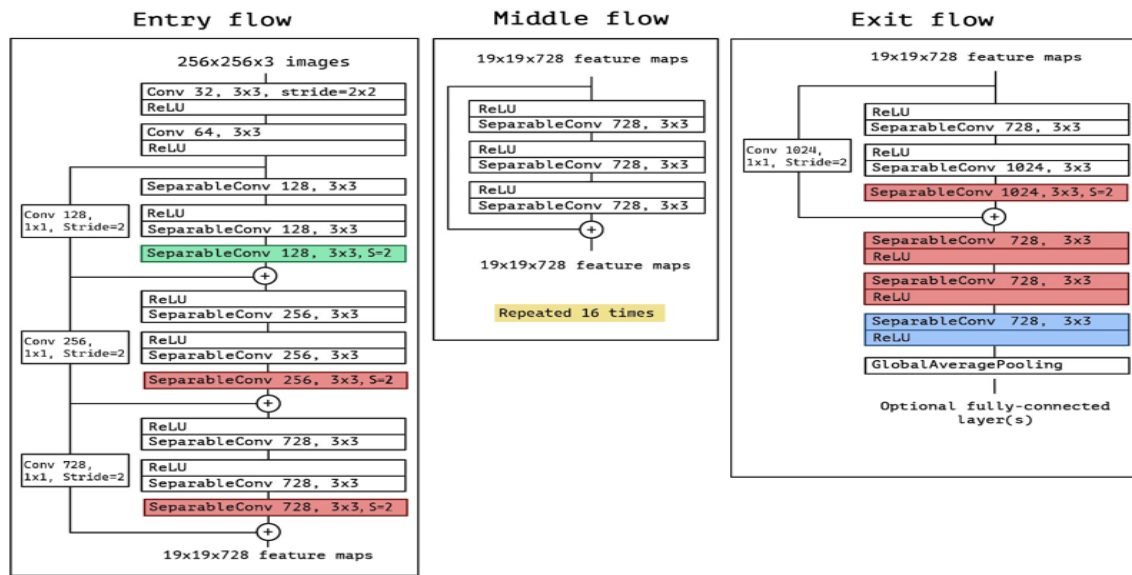
$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (S_{max} - 1) \right) \quad (2)$$

Dimana:

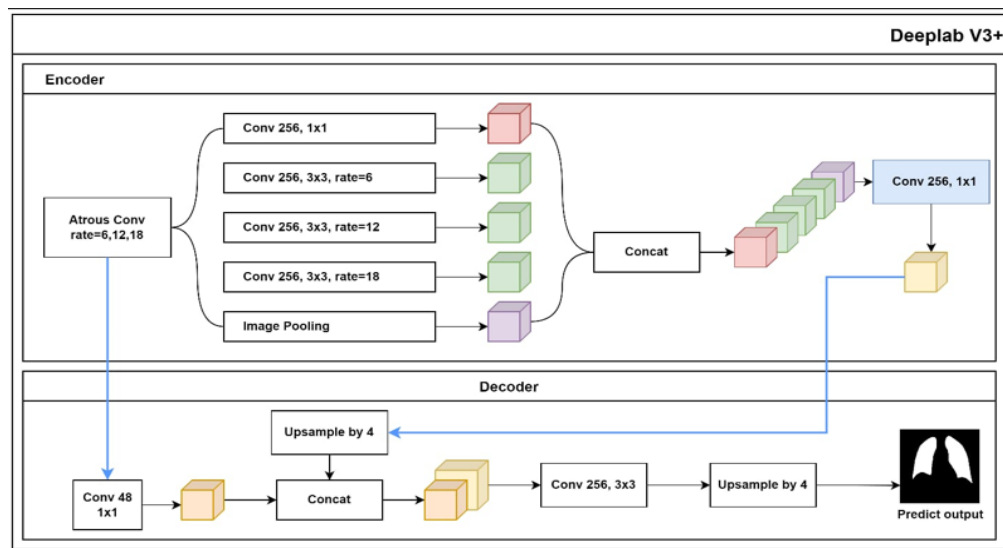
- β : nilai batas untuk perpotongan semua histogram
- M : luas *region size*
- N : nilai *grayscale*
- α : *clip factor* batas limit histogram (0-100)
- S_{max} : nilai kemiringan maksimum

2.4 Modified Aligned Xception

Pada penelitian ini mengimplementasikan *Modified Aligned Xception* yang merupakan modifikasi dari model *Aligned Xception* (El-Bana et al., 2020). Beberapa modifikasi yang dilakukan yaitu mengubah semua *max pooling* menjadi *separable convolution*, menambahkan *batch normalization*, ReLU pada setiap konvolusi 3×3 , dan mengubah *repeated 8 times* menjadi *repeated 16 times*. Selain itu, penelitian ini juga menambahkan skip koneksi kedua pada arsitektur *DeepLabV3+* berupa Conv 256, 1×1 , Stride = 2 seperti yang ditunjukkan pada Gambar 2 (kotak orange). Sementara itu, Gambar 3 merupakan arsitektur *DeepLabV3+* yang diimplementasikan pada penelitian ini.



Gambar 2. Arsitektur Modified Aligned Xception



Gambar 3. Arsitektur DeepLabV3+

2.5 Dice Similarity Coefficient (DSC)

Dice Similarity Coefficient (DSC) atau sering disebut *Dice Coefficient* (DC) merupakan salah satu metode evaluasi untuk mengukur tingkat kesamaan antara dua kumpulan data (Khan et al., 2020). Persamaan DSC ditunjukkan pada persamaan 3:

$$DSC = 2 \frac{TP}{T+P} \times 100\% \quad (3)$$

$$DSC = \frac{2TP}{2TP+FP+FN} 100\% \quad (4)$$

Keterangan:


- T : Citra Target
- P : Citra Hasil Prediksi
- \cap : Intersection atau irisan
- TP : True Positive
- FP : False Positive

FN : False Negative

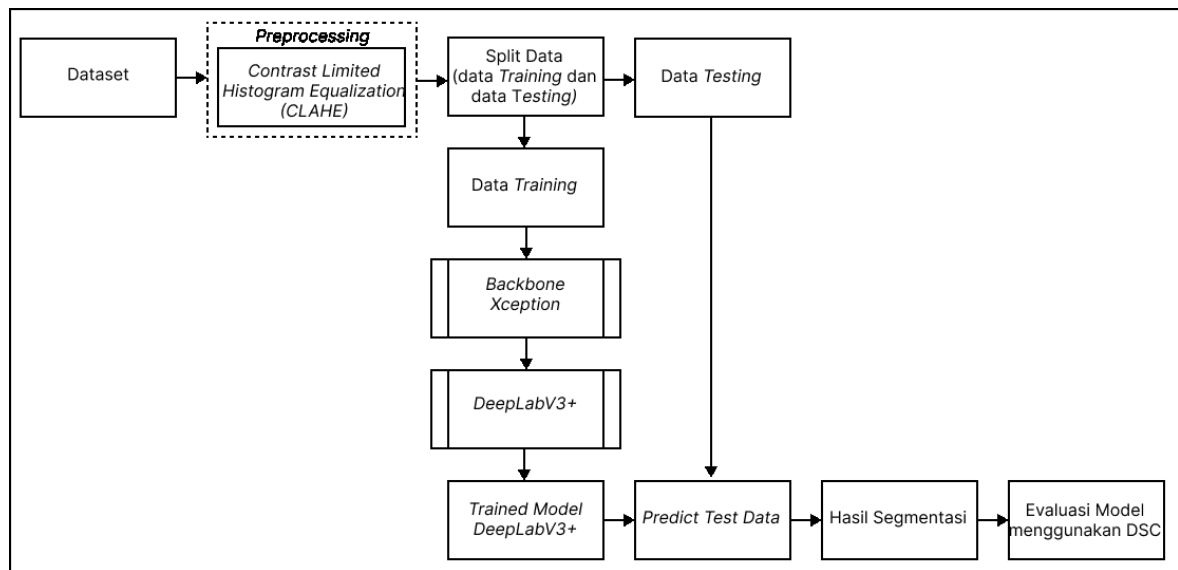
3. METODE PENELITIAN

3.1 Dataset

Dataset yang digunakan bersumber dari alamat berikut: <https://www.kaggle.com/datasets/anasmohamedmedtahir/covidqu>. Dimana pada alamat tersebut berisi citra *x-ray* dada beserta *mask* areanya dengan total data berjumlah 33.920 data.



Gambar 4. X-ray dada dan mask

Gambar 5. Arsitektur *training* dan *testing*

Untuk data yang digunakan sebanyak 1.500 data yang diambil secara acak. Berikut rincian data yang digunakan:

Tabel 1. Jumlah data yang digunakan

Data	Jumlah Data
<i>X-ray</i> dada yang terdeteksi covid	500
<i>X-ray</i> dada yang terdeteksi pneumonia	500
<i>X-ray</i> dada normal	500
Total	1.500

3.2 Arsitektur Sistem

Arsitektur *training* dan *testing* ditunjukkan oleh Gambar 4 yang meliputi proses sebagai berikut:

1. *Dataset* yang digunakan berukuran 256x256.
2. *Dataset* tersebut dimasukkan dan dilakukan *preprocessing* menggunakan CLAHE.
3. Setelah tahap *preprocessing* selesai, *dataset* dibagi menjadi data *train* dan data *testing* dengan perbandingan 80% 20%.
4. Data *train* akan dilakukan proses *training* dengan menggunakan *DeepLabV3+*. Pada tahapan ini data *train* dimasukkan ke *backbone* untuk mendapatkan *input* untuk *encoder* dan *decoder*. Setelah dari proses *backbone* dilanjutkan proses *DeepLabV3+* yang didalamnya ada proses *encoder* dan *decoder*.
5. Setelah proses *training* selesai maka didapatkan *trained model DeepLabV3+*.
6. Selanjutnya dilakukan *predict test* data menggunakan data *test*.
7. Setelah proses *testing* selesai maka didapatkan hasil segmentasi yang kemudian dilakukan evaluasi model segmentasi *DeepLabV3+*.
8. Evaluasi model segmentasi ini menggunakan *Dice Similarity Coefficient* (DSC).

3.3 Skenario Uji Coba

Skenario ujicoba dilakukan untuk mengetahui jawaban dari rumusan masalah terkait dengan tingkat akurasi yang diperoleh dari model segmentasi *x-ray* dada menggunakan arsitektur *DeepLabV3+*.

Tahapan pertama *dataset* yang telah diambil secara acak dikumpulkan. Kemudian, dilakukan *preprocessing* menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE).

Selanjutnya, *dataset* yang sudah di *preprocessing* dibagi menjadi data *train* dan data *test* dengan perbandingan 80% data *train* dan 20% data *testing*. Data *train* dimasukkan dalam arsitektur *DeepLabV3+* seperti pada Gambar 5. Arsitektur tersebut akan dijadikan acuan untuk proses segmentasi. Setelah proses *training* selesai dilanjutkan pada proses *testing*.

Kemudian model tersebut akan dilakukan perubahan *learning rate* serta *preprocessing* CLAHE dan tanpa *preprocessing* CLAHE. Hal tersebut bertujuan untuk mengetahui pengaruh terhadap hasil evaluasi model segmentasi *DeepLabV3+*. Selanjutnya, *Dice Similarity Coefficient* (DSC) merupakan metode evaluasi yang akan digunakan untuk menghitung hasil evaluasi tersebut. Tabel 2 merupakan skenario uji coba pada penelitian ini.

Tabel 2. Nilai *Learning Rate* dan *Preprocessing*

No	Learning Rate	CLAHE
1	0,01	Menggunakan CLAHE
2	0,01	Tanpa CLAHE
3	0,0001	Menggunakan CLAHE
4	0,0001	Tanpa CLAHE

4. HASIL DAN PEMBAHASAN

4.1 Uji Coba *Learning Rate* 0,01 Tanpa *Preprocessing* CLAHE

Pada percobaan ini menggunakan 20 *epoch*, *learning rate* = 0,01, dan tanpa menggunakan *preprocessing* CLAHE. Tabel 3 dan Gambar 5 merupakan hasil dari percobaan ini.


Tabel 3. Hasil Skenario Uji Coba *Learning Rate* 0,01 tanpa CLAHE

Epoch	loss	dice_coef	val_loss	val_dice_coef
1	16,60%	83,40%	14,06%	85,94%
2	8,17%	91,83%	12,74%	87,26%
3	6,31%	93,69%	7,43%	92,57%
4	5,00%	95,00%	9,09%	90,91%
5	4,61%	95,39%	17,93%	82,07%
6	4,19%	95,81%	4,20%	95,80%
7	3,94%	96,06%	4,90%	95,10%
8	3,80%	96,20%	9,04%	90,96%
9	3,54%	96,46%	4,06%	95,94%
10	3,49%	96,51%	13,13%	86,87%
11	3,35%	96,65%	3,93%	96,07%
12	3,22%	96,78%	5,89%	94,11%
13	3,25%	96,75%	4,86%	95,14%
14	3,39%	96,61%	4,67%	95,33%
15	2,91%	97,09%	3,84%	96,16%
16	3,02%	96,98%	3,67%	96,33%
17	2,81%	97,19%	3,79%	96,21%
18	2,89%	97,11%	3,80%	96,20%
19	2,76%	97,24%	3,56%	96,44%
20	2,70%	97,30%	30,57%	69,43%

Setelah dilakukan uji coba skenario dengan *learning rate* 0,01 dan tanpa menggunakan *preprocessing* CLAHE didapatkan hasil nilai evaluasi terbaik pada *epoch* ke-19 dengan menggunakan *Dice Similarity Coefficient* sebesar 96,44%. Nilai ini menyatakan bahwa hasil segmentasi yang sangat baik, artinya hanya terdapat 3,56% kesalahan antara citra *groundtruth* dengan citra hasil model *DeepLabV3+*.

4.2 Uji Coba *Learning Rate* 0,01 Dengan *Preprocessing* CLAHE

Pada percobaan ini menggunakan 20 *epoch*, *learning rate* = 0,01, dan menggunakan *preprocessing* CLAHE. Tabel 4 dan Gambar 6 merupakan hasil dari percobaan ini.




Gambar 6. Grafik Hasil Skenario Uji Coba *Learning Rate* 0,01 Tanpa CLAHE


Tabel 4. Hasil Skenario Uji Coba *Learning Rate* 0,01 menggunakan CLAHE

Epoch	loss	dice_coef	val_loss	val_dice_coef
1	13,76%	86,24%	25,42%	74,58%
2	7,49%	92,51%	8,59%	91,41%
3	6,12%	93,88%	40,09%	59,91%
4	5,23%	94,77%	8,86%	91,14%
5	4,81%	95,19%	15,01%	84,99%
6	4,43%	95,57%	5,89%	94,11%
7	4,34%	95,66%	6,84%	93,16%
8	4,16%	95,84%	5,35%	94,65%
9	3,87%	96,13%	4,74%	95,26%
10	3,64%	96,36%	4,67%	95,33%
11	3,51%	96,49%	4,60%	95,40%
12	3,36%	96,64%	4,30%	95,70%
13	3,31%	96,69%	5,33%	94,67%
14	3,22%	96,78%	4,90%	95,10%
15	3,63%	96,37%	4,55%	95,45%
16	3,25%	96,75%	4,14%	95,86%
17	2,99%	97,01%	3,95%	96,05%
18	3,03%	96,97%	3,84%	96,16%
19	2,87%	97,13%	3,86%	96,14%
20	2,91%	97,09%	3,86%	96,14%

Setelah dilakukan uji coba skenario dengan *learning rate* 0,01 dan menggunakan *preprocessing* CLAHE didapatkan hasil nilai evaluasi terbaik pada *epoch* ke-20 dengan menggunakan *Dice Similarity Coefficient* sebesar 96,14%. Nilai ini menyatakan bahwa hasil segmentasi yang baik, artinya hanya terdapat 3,86% kesalahan antara citra *groundtruth* dengan citra hasil model *DeepLabV3+*. Berdasarkan Tabel 3 dan 4 serta visualisasi hasil uji coba menggunakan grafik pada Gambar 5 dan 6 maka penggunaan *preprocessing* dengan dan tanpa CLAHE sangat mempengaruhi hasil evaluasi uji coba menggunakan *learning rate* 0,01.



Gambar 7. Grafik Hasil Skenario Uji Coba *Learning Rate* 0,01 Menggunakan CLAHE



Gambar 8. Grafik Hasil Skenario Uji Coba *Learning Rate* 0,0001 Tanpa CLAHE

4.3 Uji Coba *Learning Rate* 0,0001 Tanpa Preprocessing CLAHE

Pada percobaan ini menggunakan 20 *epoch*, *learning rate* = 0,0001, dan tanpa menggunakan *preprocessing* CLAHE. Tabel 5 dan Gambar 8 merupakan hasil dari percobaan ini.

Tabel 5. Hasil Skenario Uji Coba *Learning Rate* 0,0001 tanpa CLAHE

Epoch	loss	dice_coef	val_loss	val_dice_coef
1	13,54%	86,46%	98,77%	1,23%
2	6,15%	93,85%	43,80%	56,20%
3	4,68%	95,32%	5,72%	94,28%
4	3,85%	96,15%	5,82%	94,18%
5	3,32%	96,68%	5,06%	94,94%
6	3,00%	97,00%	5,41%	94,59%
7	2,79%	97,21%	9,10%	90,90%
8	2,68%	97,32%	4,74%	95,26%
9	2,55%	97,45%	4,70%	95,30%
10	2,35%	97,65%	4,46%	95,54%
11	2,23%	97,77%	4,45%	95,55%
12	2,14%	97,86%	4,21%	95,79%
13	2,01%	97,99%	4,25%	95,75%
14	1,91%	98,09%	4,60%	95,40%
15	1,82%	98,18%	4,42%	95,58%
16	1,78%	98,22%	4,37%	95,63%
17	1,72%	98,28%	4,29%	95,71%
18	1,70%	98,30%	4,47%	95,53%
19	1,67%	98,33%	4,10%	95,90%
20	1,62%	98,38%	4,11%	95,89%

Setelah dilakukan uji coba skenario dengan *learning rate* 0,0001 dan tanpa menggunakan *preprocessing* CLAHE didapatkan hasil nilai evaluasi terbaik pada *epoch* ke-19 dengan menggunakan *Dice Similarity Coefficient* sebesar 95,90%. Nilai ini menyatakan bahwa hasil segmentasi yang baik, artinya hanya terdapat 4,10% kesalahan antara citra *groundtruth* dengan citra hasil model *DeepLabV3+*.

4.4 Uji Coba *Learning Rate* 0,0001 Dengan Preprocessing CLAHE


Pada percobaan ini menggunakan 20 *epoch*, *learning rate* = 0,0001, dan menggunakan *preprocessing* CLAHE. Tabel 6 dan Gambar 9 merupakan hasil dari percobaan ini.

Tabel 6. Hasil Skenario Uji Coba *Learning Rate* 0,0001 menggunakan CLAHE

Epoch	Loss	dice_coef	val_loss	val_dice_coef
1	13,03%	86,97%	97,17%	2,83%
2	6,03%	93,97%	32,54%	67,46%
3	4,73%	95,27%	6,54%	93,46%
4	3,90%	96,10%	5,67%	94,33%
5	3,40%	96,60%	5,38%	94,62%
6	2,97%	97,03%	5,08%	94,92%
7	2,78%	97,22%	4,66%	95,34%
8	2,55%	97,45%	4,75%	95,25%
9	2,47%	97,53%	4,93%	95,07%
10	2,34%	97,66%	4,61%	95,39%
11	2,25%	97,75%	4,49%	95,51%
12	2,11%	97,89%	4,51%	95,49%
13	1,99%	98,01%	4,34%	95,66%
14	1,90%	98,10%	4,53%	95,47%
15	1,87%	98,13%	4,35%	95,65%
16	1,76%	98,24%	4,25%	95,75%
17	1,73%	98,27%	4,42%	95,58%
18	1,70%	98,30%	4,32%	95,68%
19	1,65%	98,35%	4,09%	95,91%
20	1,61%	98,39%	4,03%	95,97%

Setelah dilakukan uji coba skenario dengan *learning rate* 0,0001 dan menggunakan *preprocessing* CLAHE didapatkan hasil nilai evaluasi terbaik pada *epoch* ke-20 dengan menggunakan *Dice Similarity Coefficient* sebesar 95,97%. Nilai ini menyatakan bahwa hasil segmentasi yang baik, artinya hanya terdapat 4,03% kesalahan antara citra *groundtruth* dengan citra hasil model *DeepLabV3+*. Berdasarkan Tabel 5 dan 6 serta visualisasi hasil uji coba menggunakan grafik pada

Gambar 7 dan 9 maka penggunaan *preprocessing* dengan dan tanpa CLAHE sangat mempengaruhi hasil evaluasi uji coba menggunakan *learning rate* 0,0001.



Gambar 9. Grafik Hasil Skenario Uji Coba *Learning Rate* 0,0001 Menggunakan CLAHE


4.5 Hasil Perbandingan Evaluasi Keseluruhan Sistem

Pada penelitian ini telah dilakukan 4 skenario uji coba dan setiap skenario memiliki nilai evaluasi DSC masing-masing. Tabel 7 dan Gambar 10 merupakan hasil evaluasi DSC dari setiap skenario uji coba.

Tabel 7. Hasil Perbandingan Evaluasi DSC pada 4 Skenario Uji Coba

Epoch	Skenario 1	Skenario 2	Skenario 3	Skenario 4
1	85,94%	74,58%	1,23%	2,83%
2	87,26%	91,41%	56,20%	67,46%
3	92,57%	59,91%	94,28%	93,46%
4	90,91%	91,14%	94,18%	94,33%
5	82,07%	84,99%	94,94%	94,62%
6	95,80%	94,11%	94,59%	94,92%
7	95,10%	93,16%	90,90%	95,34%
8	90,96%	94,65%	95,26%	95,25%
9	95,94%	95,26%	95,30%	95,07%
10	86,87%	95,33%	95,54%	95,39%
11	96,07%	95,40%	95,55%	95,51%
12	94,11%	95,70%	95,79%	95,49%
13	95,14%	94,67%	95,75%	95,66%
14	95,33%	95,10%	95,40%	95,47%
15	96,16%	95,45%	95,58%	95,65%
16	96,33%	95,86%	95,63%	95,75%
17	96,21%	96,05%	95,71%	95,58%
18	96,20%	96,16%	95,53%	95,68%
19	96,91%	96,14%	95,90%	95,91%
20	69,43%	96,14%	95,89%	95,97%

Setelah dilakukan perbandingan skenario uji coba, uji coba yang dengan skenario *learning rate* 0,01 dan tanpa menggunakan *preprocessing Contrast Limited Adaptive Histogram Equalization* (CLAHE) mendapatkan hasil evaluasi tertinggi dengan menggunakan *Dice Similarity Coefficient* (DSC) sebesar 96,91%. Nilai DSC tertinggi ini diperoleh pada *epoch* ke-19.



Gambar 10. Hasil Perbandingan Evaluasi Semua Skenario Uji Coba

4.6 Visualisasi Hasil Uji Coba

Gambar 10 – 12 merupakan contoh visualisasi hasil uji coba segmentasi citra *x-ray* dada menggunakan model *DeepLabV3+*, masing - masing untuk kelas Normal, Covid-19 dan Pneumonia. Berdasarkan ketiga gambar tersebut, model *DeepLabV3+* mampu melakukan segmentasi paru-paru dari citra *x-ray* dada dengan baik yaitu dengan akurasi 96,91%.

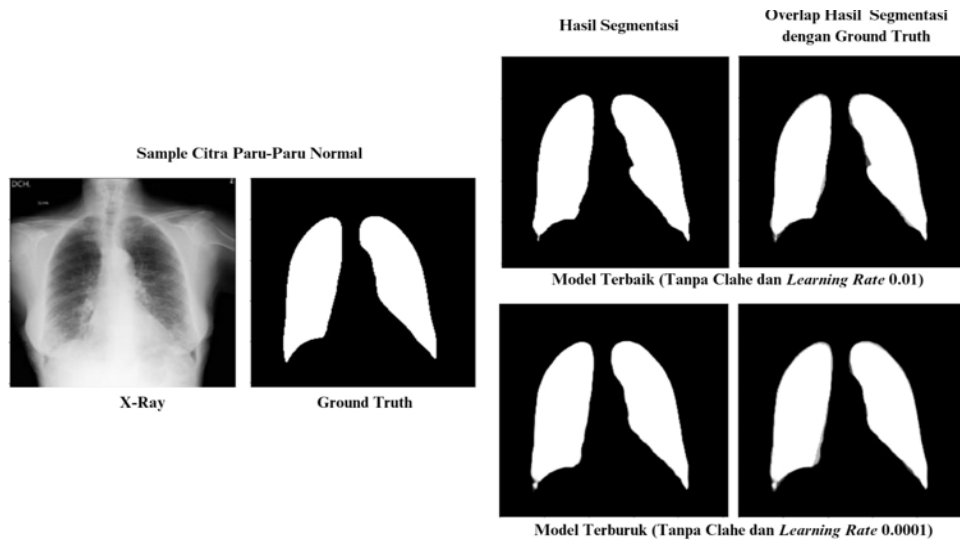
4.7 Perbandingan dengan Metode *Backbone* Lainnya

Penelitian ini juga membandingkan hasil segmentasi paru-paru menggunakan metode usulan *DeepLabV3+ (Backbone Modified Aligned Xception)* dengan *DeepLabV3+ Backbone Aligned Xception* dan *Xception* biasa. Parameter yang digunakan saat ujicoba metode adalah pembagian data menjadi 80% data *training*, 10% data *validation*, dan 10% data *testing*. Selain itu, *learning rate* = 10^{-2} , *batch size* = 4, *epoch* = 20 serta *optimizer* = Adam. Tabel 8 dan Gambar 13 menunjukkan hasil perbandingan eksperimennya.

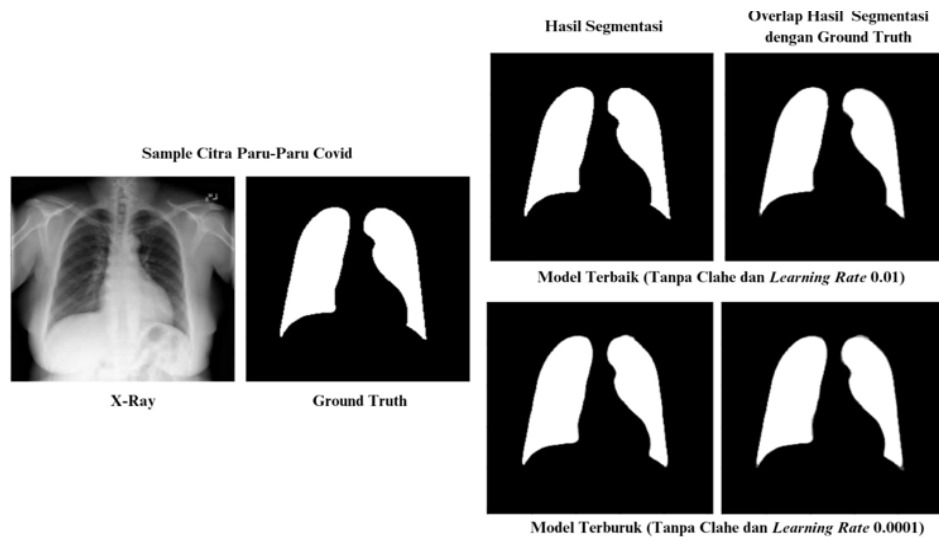
Tabel 8. Hasil Perbandingan Metode *DeepLabV3+*

<i>Backbone</i>	Val Loss (%)	Val Dice (%)	Hasil Testing (%)
Xception	3,14	96,87	96,39
Aligned Xception	3,35	96,66	94,81
Modified Aligned Xception (metode usulan)	3,1	96,91	95,64


Berdasarkan Tabel 8 menunjukkan bahwa *backbone Modified Aligned Xception DeepLabV3+* memperoleh hasil Val Dice tertinggi yaitu 96,91%. Hasil ini juga ditunjukkan pada Gambar 13 yaitu visualisasi perbandingan ketiga *backbone* yang berbeda pada *DeepLabV3+*. Kotak kuning menunjukkan indikasi overlap yang berbeda antara citra *ground-truth* dengan hasil model *DeepLabV3+* dari ketiga *backbone* tersebut. Model yang diusulkan memiliki *error* yang lebih kecil yaitu 3,1%.




Gambar 10. Visualisasi Hasil Uji Coba Model *DeepLabV3+* untuk Kelas Normal



Gambar 11. Visualisasi Hasil Uji Coba Model *DeepLabV3+* untuk Kelas Covid-19



Gambar 12. Visualisasi Hasil Uji Coba Model *DeepLabV3+* untuk Kelas Pneumonia

Gambar 13. Visualisasi Perbandingan Model *DeepLabV3+*

5. KESIMPULAN

Penelitian ini telah berhasil melakukan ujicoba dengan modifikasi pada *backbone Xception* pada arsitektur *DeepLabV3+*. Dari hasil skenario uji coba yang telah dilakukan pada citra X-ray dada dapat diambil kesimpulan bahwa uji coba dengan skenario 1 yaitu *learning rate* 0,01 dan tanpa menggunakan *preprocessing Contrast Limited Adaptive Histogram Equalization* (CLAHE) mendapatkan hasil evaluasi tertinggi dengan menggunakan *Dice Similarity Coefficient* (DSC) sebesar 96,91%. Dengan demikian, metode segmentasi berbasis *Deep Learning* ini dapat dijadikan rujukan paramedis dalam mensegmentasi paru-paru pasien.

6. UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Rumah Sakit Universitas Airlangga (RSUA), RSPHC Surabaya dan repositori Kaggle yang telah menyediakan dataset *x-ray* dada untuk uji coba metode pada penelitian ini dan Badan Riset dan Inovasi Nasional (BRIN) yang telah memberikan dana penelitian Riset dan Inovasi untuk Indonesia Maju (RIIM) gelombang 1 dengan nomer kontrak (induk) 52/IV/KS/06/2022 dan kontrak (turunan) 2988/UN46.4.1/PT/00.03/2022.

DAFTAR PUSTAKA

BASO, B., & SUCIATI, N. 2020. Temu Kembali Citra Tenun Nusa Tenggara Timur menggunakan Ekstraksi Fitur yang Robust terhadap Perubahan Skala, Rotasi, dan Pencahayaan. *Jurnal Teknologi Informasi Dan*

Ilmu Komputer, 7(2), 349.
<https://doi.org/10.25126/jtik.2020722002>

CHEN, L.-C., PAPANDREOU, G., KOKKINOS, I., MURPHY, K., & YUILLE, A. L. 2014. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs. *ArXiv*, 40(4), 1–14.
<https://doi.org/https://doi.org/10.48550/arXiv.1412.7062>

CHEN, L.-C., PAPANDREOU, G., KOKKINOS, I., MURPHY, K., & YUILLE, A. L. 2018. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848.
<https://doi.org/10.1109/TPAMI.2017.2699184>

CHEN, L.-C., PAPANDREOU, G., SCHROFF, F., & ADAM, H. 2017. Rethinking Atrous Convolution for Semantic Image Segmentation. *ArXiv*.
<http://arxiv.org/abs/1706.05587>

CHEN, L.-C., ZHU, Y., PAPANDREOU, G., SCHROFF, F., & ADAM, H. 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 833–851. https://doi.org/10.1007/978-3-030-01234-2_49

CHENG, J., TIAN, S., YU, L., LU, H., & LV, X. 2020. Fully convolutional attention network for biomedical image segmentation. *Artificial Intelligence in Medicine*, 107(June), 101899.

- <https://doi.org/10.1016/j.artmed.2020.101899>
 EL-BANA, S., AL-KABBANY, A., & SHARKAS, M. 2020. A multi-task pipeline with specialized streams for classification and segmentation of infection manifestations in COVID-19 scans. *PeerJ Computer Science*, 6, 1–27. <https://doi.org/10.7717/peerj-cs.303>
- HASMA, Y. A., & SILFIANTI, W. 2018. Implementasi Deep Learning Menggunakan Framework Tensorflow Dengan Metode Faster Regional Convolutional Neural Network Untuk Pendeteksian Jerawat. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 23(2), 89–102. <https://doi.org/10.35760/tr.2018.v23i2.2459>
- KAUR, D., & KAUR, Y. (2014). Various Image Segmentation Techniques: A Review. *International Journal of Computer Science and Mobile Computing*, 3(5), 809–8014.
- KHAN, Z., YAHYA, N., ALSAIH, K., ALI, S. S. A., & MERIAUDEAU, F. 2020. Evaluation of deep neural networks for semantic segmentation of prostate in T2W MRI. *Sensors (Switzerland)*, 20(11), 1–17. <https://doi.org/10.3390/s20113183>
- KUMASEH, M. R., LATUMAKULITA, L., & NAINGGOLAN, N. (2013). Segmentasi Citra Digital Ikan Menggunakan Metode Thresholding. *Jurnal Ilmiah Sains*, 13(1), 75–79. <https://doi.org/10.35799/jis.17.2.2017.18128>
- MULLER, D., SOTO-REY, I., & KRAMER, F. 2020. Automated Chest CT Image Segmentation of COVID-19 Lung Infection based on 3D U-Net. *ArXiv, abs/2007.0*, 1–9. <https://www.semanticscholar.org/paper/Automated-Chest-CT-Image-Segmentation-of-COVID-19-Müller-Rey/7c30e2d18c5caa81507a44c80410eb33226f3f42>
- NUGROHO, P. A., FENRIANA, I., & ARIJANTO, R. 2020. Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Algor*, 2(1), 12–21.
- ROTHAN, H. A., & BYRAREDDY, S. N. (2020). The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak. *Journal of Autoimmunity*, 109(February), 102433. <https://doi.org/10.1016/j.jaut.2020.102433>
- SAOOD, A., & HATEM, I. (2021). COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet. *BMC Medical Imaging*, 21(1), 1–10. <https://doi.org/10.1186/s12880-020-00529-5>
- SHI, F., WANG, J., SHI, J., WU, Z., WANG, Q., TANG, Z., HE, K., SHI, Y., & SHEN, D. (2021). Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation, and Diagnosis for COVID-19. *IEEE Reviews in Biomedical Engineering*, 14, 4–15. <https://doi.org/10.1109/RBME.2020.2987975>
- SUSANTO, A. 2019. Penerapan Operasi Morfologi Matematika Citra Digital untuk Ekstraksi Area Plat Nomor Kendaraan Bermotor. *Pseudocode*, VI, 9.
- SUSILO, A., dkk. 2020. Coronavirus Disease 2019: Tinjauan Literatur Terkini. *Jurnal Penyakit Dalam Indonesia*, 7(1), 45–67. <https://doi.org/10.25104/transla.v22i2.1682>
- WHO. 2022. COVID-19 Weekly Epidemiological Update. In *World Health Organization* (Issue February). <https://www.who.int/publications/m/item/weekly-epidemiological-update-on-covid-19---21-september-2022>
- YAN, Q., WANG, B., GONG, D., LUO, C., ZHAO, W., SHEN, J., SHI, Q., JIN, S., ZHANG, L., & YOU, Z. 2020. COVID-19 Chest CT Image Segmentation - A Deep Convolutional Neural Network Solution. *ArXiv, abs/2004.1*, 1–10. <http://arxiv.org/abs/2004.10987>
- YUDISTIRA, N., WIDODO, A. W., & RAHAYUDI, B. 2020. Deteksi Covid-19 pada Citra Sinar-X Dada Menggunakan Deep Learning yang Efisien. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 7(6), 1289. <https://doi.org/10.25126/jtiik.2020763651>

Halaman ini sengaja dikosongkan