

KLASIFIKASI CITRA X-RAY TORAKS DENGAN MENGGUNAKAN CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION DAN CONVOLUTIONAL NEURAL NETWORK (STUDI KASUS: PNEUMONIA)

Surya Adi Widiarto¹⁾, Wahyu Andi Saputra²⁾, Atika Ratna Dewi³⁾

^{1, 2)}Program Studi S1 Teknik Informatika, Fakultas Informatika, Institut Teknologi Telkom Purwokerto

³⁾Program Studi S1 Sains Data, Fakultas Informatika, Institut Teknologi Telkom Purwokerto
Jl. D.I Panjaitan, No. 128, Purwokerto Selatan, Banyumas, Jawa Tengah, 53147

e-mail: 17102189@ittelkom-pwt.ac.id¹⁾, andi@ittelkom-pwt.ac.id²⁾, atika@ittelkom-pwt.ac.id³⁾

ABSTRAK

Pneumonia merupakan penyakit yang menyerang paru-paru. Ketika seseorang dicurigai sebagai penderita pneumonia maka akan dilakukan berbagai pemeriksaan untuk memastikan hasil diagnosis, salah satunya yaitu pemeriksaan pada citra x-ray toraks. Namun, terdapat kemungkinan dokter/radiologis melakukan kesalahan dalam melakukan interpretasi. Untuk meminimalisir hal tersebut diperlukan terbososan guna membantu dokter/radiologis dalam menganalisis citra x-ray toraks. Salah satunya adalah dengan menerapkan penggunaan Convolutional Neural Network (CNN), dimana harapannya CNN dapat digunakan untuk mengenali citra x-ray toraks sehat dan berpneumonia. Akan tetapi terdapat faktor yang dapat menyebabkan citra x-ray menjadi buruk, sehingga dimungkinkan dapat mempengaruhi hasil perolehan CNN. Untuk mengatasi hal tersebut Contrast Limited Adaptive Histogram Equalization (CLAHE) digunakan untuk melakukan perbaikan citra sebelum citra diterapkan pada CNN. Selain itu penggunaan beberapa epoch dan ukuran gambar yang berbeda juga diterapkan untuk mengetahui pengaruh pada hasil yang diperoleh model, dimana kemudian hasil-hasil yang diperoleh tersebut dilakukan analisis untuk mengetahui model mana yang memperoleh hasil terbaik. Setelah dilakukan pengujian, diperoleh hasil perolehan terbaik pada model dengan penerapan CLAHE pada epoch 180 dengan ukuran 256x256 yang memperoleh tingkat akurasi sebesar 95,21%.

Kata Kunci: CLAHE, CNN, Pneumonia.


ABSTRACT

Pneumonia is a disease that attacks the lung. When someone is suspected of having pneumonia, various examinations will be carried out to confirm the diagnosis, one of them is by examining the chest x-ray image. However, there is a possibility that the doctor/radiologist may make a mistake in interpreting it. To minimize this, a breakthrough is needed for assisting doctors/radiologists in analyzing chest x-ray image. One of them is by applying the use of Convolutional Neural Network (CNN), where it is hoped that CNN can be used for recognizing healthy and pneumonia chest x-ray images. However, some factors can cause the x-ray image to be bad, so it is possible that it can affect the CNN acquisition results. To overcome this, Contrast Limited Adaptive Histogram Equalization (CLAHE) is used to improve the image before the image is applied to CNN. Moreover, the use of several epochs and different image sizes is also applied to determine the effect on the results obtained by the model, which then the acquisition results were analyzed to find out which model get the best results. After testing was done, the best results were obtained on the model with the application of CLAHE on epoch 180 with a size of 256x256 which obtained an accuracy rate of 95,21%.

Keywords: CLAHE, CNN, Pneumonia.


I. PENDAHULUAN

PNEUMONIA merupakan suatu bentuk infeksi pernapasan akut yang menyerang paru-paru [1]. Pneumonia sendiri dapat disebabkan oleh virus, bakteri, maupun jamur, dan hal tersebut menyebabkan setiap orang memiliki resiko menderita pneumonia. Selain itu gejala ringan dari pneumonia yang umumnya seperti batuk kering, flu pilek, demam menggigil, nyeri otot, nyeri dada, mual, sakit perut, dan muntah [2] menyebabkan sebagian besar penderita kurang begitu memperhatikan kondisi kesehatan. Menurut WHO pada tahun 2017, pneumonia menjadi penyebab 15% kematian anak-anak berusia dibawah 5 tahun (balita) diseluruh dunia, yaitu sebanyak 808,694 anak [1].



Gambar 1. Statistik Jumlah Kasus Pneumonia 2012-2018 [3]

Kemudian berdasarkan data statistik yang diperoleh dari kementerian kesehatan Indonesia pada tahun 2012-2018 yang dapat dilihat pada gambar 1, di Indonesia sendiri terdapat cukup banyak kasus pneumonia. Pada tahun 2015 jumlah kasus penderita pneumonia di Indonesia mencapai 554,650 jiwa, berikutnya pada tahun 2016 jumlah kasus penderita pneumonia di Indonesia mengalami peningkatan menjadi 568,146 jiwa, sedangkan pada tahun 2018 jumlah kasus penderita pneumonia di Indonesia mencapai 478,078 jiwa. Selain itu di Indonesia sendiri juga terdapat cukup banyak jumlah angka kematian yang disebabkan oleh pneumonia, dimana pada tahun 2017 jumlah angka kematian mencapai 43,764 jiwa dan tersebar dari berbagai kalangan usia yang dapat dilihat pada gambar 2 berikut.



Gambar 2. Statistik Jumlah Kasus Kematian Pneumonia 2017 [4]

Tingginya jumlah kasus penderita dan kematian yang disebabkan oleh pneumonia di Indonesia ini menandakan bahwa pendeteksian dan penanganan pneumonia di Indonesia harus ditinjau dengan serius. Ketika seseorang dicurigai sebagai penderita pneumonia maka akan dilakukan wawancara medis, pemeriksaan fisis umum dan paru, pemeriksaan citra *x-ray* toraks, pemeriksaan darah, serta pemeriksaan bakteri penyebab dari dahak [5]. Dari berbagai tahap dalam melakukan diagnosis tersebut, pemeriksaan citra *x-ray* toraks merupakan salah satu tahap penting. Namun, terdapat kemungkinan dokter/radiologis melakukan kesalahan dalam melakukan interpretasi citra *x-ray* toraks.

Kesalahan interpretasi sebagian besar dikarenakan kesalahan persepsi, dimana kesalahan persepsi bertanggung jawab atas 60-80% kesalahan interpretasi [6]. Ahli radiologi menggunakan deteksi visual, pengenalan pola, ingatan, dan penalaran kognitif untuk menyimpulkan hasil akhir interpretasi. Penyimpulan ini dilakukan di lingkungan yang terdapat berbagai pengalih perhatian, beban kerja yang meningkat, dan kelelahan [6]. Oleh karena itu kesalahan interpretasi mungkin dapat tidak terhindarkan. Dengan demikian diperlukan sebuah terobosan dalam membantu dokter/radiologis dalam menganalisis citra *x-ray* toraks terduga penderita untuk mendiagnosis pneumonia, salah satunya adalah dengan mengikuti perkembangan teknologi terbaru agar terjadinya kesalahan interpretasi dapat diminimalisir.

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multi Layer Perceptron* (MLP) yang dirancang untuk mengolah data 2D (dua dimensi) [7]. CNN juga termasuk kedalam *Deep Neural Network* (DNN) dikarenakan CNN memiliki jaringan yang dalam dan berlapis-lapis [8]. Terdapat beberapa penelitian yang telah menggunakan CNN sebagai metode yang digunakan untuk melakukan klasifikasi, diantaranya yaitu penelitian [9], [10], dan [11]. Dari beberapa penelitian tersebut, CNN menunjukkan kinerja yang baik dalam melakukan klasifikasi

dengan perolehan akurasi diatas 80%. Dengan menerapkan CNN pada citra *x-ray* toraks, harapannya CNN dapat mengenali perbedaan citra *x-ray* toraks sehat dengan citra *x-ray* toraks berpneumonia, sehingga CNN dapat melakukan klasifikasi dengan perolehan akurasi yang baik.


Namun, terdapat faktor-faktor yang dapat menyebabkan citra *x-ray* menjadi buruk. Faktor-faktor tersebut diantaranya yaitu peralatan yang tidak mumpuni, kesalahan operator, dan kelainan pasien. Hal tersebut dapat menyebabkan citra *x-ray* memiliki detail yang tidak memadai serta kontras dan pencahayaan yang rendah [12], sehingga terdapat kemungkinan hal tersebut juga dapat mempengaruhi akurasi yang diperoleh CNN. Oleh karena itu sebelum menerapkan citra *x-ray* pada CNN diperlukan peningkatan kualitas citra agar kualitas citra dapat lebih baik dari citra sebelumnya, sehingga diharapkan hal tersebut dapat meningkatkan tingkat akurasi yang diperoleh. Salah satunya adalah dengan menerapkan penggunaan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) pada citra.

CLAHE merupakan teknik pengolahan citra yang digunakan untuk meningkatkan kontras pada gambar. CLAHE beroperasi pada area kecil dalam gambar yang dikenal dengan *tile* dari pada melakukan operasi pada keseluruhan gambar [13]. Selain itu permasalahan peningkatan kontras yang berlebihan dapat diatasi dengan menggunakan CLAHE, yaitu dengan memberikan nilai batas pada histogram. Nilai batas ini disebut dengan *clip limit* yang menyatakan tinggi maksimum dari sebuah histogram [14]. Beberapa penelitian yang telah menggunakan CLAHE sebagai metode untuk melakukan perbaikan citra seperti pada penelitian [15], [16], dan [17] menunjukkan bahwa CLAHE dapat dengan baik melakukan perbaikan citra. Oleh karena itu diharapkan dengan menggunakan CLAHE kualitas pencahayaan citra yang masih kurang baik dapat lebih ditingkatkan sehingga detail pada citra yang sebelumnya kurang memadai dapat lebih diperbaiki.

Penelitian ini menerapkan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan *Convolutional Neural Network* (CNN) untuk digunakan sebagai metode dalam melakukan klasifikasi pneumonia pada citra *x-ray* toraks. Oleh karena itu penelitian ini diharapkan dapat menjadi salah satu bahan pertimbangan serta memudahkan dokter/radiologis dalam menganalisis citra *x-ray* toraks, sehingga peluang terjadinya kesalahan interpretasi dapat lebih diminimalisir.

II. METODE PENELITIAN

Terdapat beberapa tahap dalam melaksanakan penelitian, yaitu diawali dengan melakukan studi pendahuluan, pengumpulan data, *preprocessing*, penerapan CNN, dan diakhiri dengan evaluasi dan kesimpulan. Tahap pertama yaitu studi pendahuluan dilakukan untuk dijadikan pondasi dalam penyusunan penelitian. Tahap kedua yaitu pengumpulan data dilakukan untuk memperoleh data-data yang diperlukan dalam penelitian. Tahap ketiga dilakukan *preprocessing* pada data sebelum data diterapkan pada tahap berikutnya. Tahap keempat adalah menerapkan data yang telah dilakukan *preprocessing* kedalam proses CNN. Tahap terakhir adalah evaluasi dan kesimpulan, dimana data-data hasil akhir yang telah diperoleh dilakukan evaluasi dan penyimpulan. Alur proses penelitian dapat dilihat seperti pada gambar 3 dibawah.



Gambar 3. Proses Penelitian

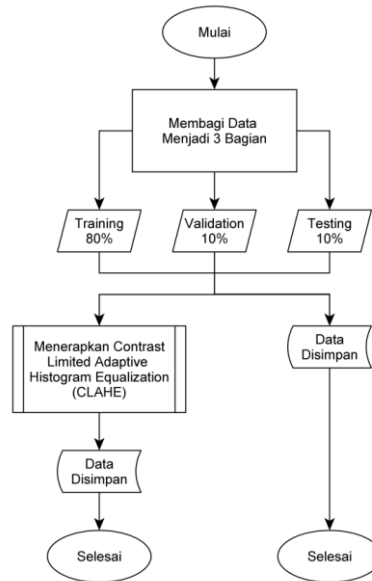
A. Studi Pendahuluan

Studi pendahuluan ini dilakukan dengan melakukan studi literatur dari berbagai sumber yang tersedia seperti jurnal, skripsi, buku, *website*, maupun sumber lain yang memiliki keterkaitan dengan permasalahan yang dihadapi.

B. Pengumpulan Data

Pengumpulan data pada penelitian ini yaitu dengan cara mencari data-data yang diperlukan dari internet, terutama pada dataset yang merupakan salah satu kunci utama pada penelitian. Setelah melakukan pencarian dataset dari berbagai sumber yang tersedia, dataset kumpulan citra *x-ray* toraks yang diperoleh dari penelitian [18] dipilih sebagai objek penelitian yang akan digunakan dalam melakukan penelitian. Dataset tersebut berisi 5856 citra *x-ray* toraks yang terdiri dari 2 kategori, yaitu normal dan pneumonia.

C. Preprocessing



Gambar 4. Proses *Preprocessing*

Pada proses ini *preprocessing* dilakukan pada data sebelum data diterapkan pada penerapan CNN. Seperti yang dapat dilihat pada gambar 4 diatas, pada proses *preprocessing* ini terdapat dua tahapan yang berbeda. Tahap pertama yaitu membagi data lalu menerapkan CLAHE terhadap data yang telah dibagi tersebut, kemudian setelah penerapan CLAHE selesai dilakukan data akan disimpan. Tahap lainnya adalah langsung melakukan penyimpanan pada data yang telah dilakukan pembagian menjadi 3 bagian tanpa dilakukan penerapan CLAHE.

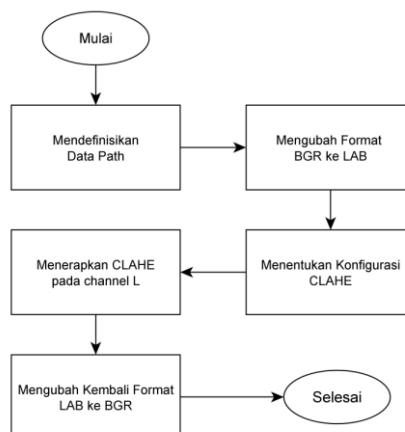
1) Pembagian Data

Pada proses ini dataset dilakukan pembagian menjadi 3 bagian secara acak, yaitu data *training*, data *validation*, dan data *testing*. Presentase pembagian data kedalam 3 bagian tersebut adalah 80% untuk data *training*, 10% untuk data *validation*, serta 10% untuk data *testing*. Jumlah pembagian data sesuai dengan kelasnya masing-masing dapat dilihat pada tabel I berikut.

TABEL I
PEMBAGIAN DATASET

	Normal	Pneumonia
<i>Training</i> (80%)	Normal (1267)	Pneumonia (3419)
<i>Validation</i> (10%)	Normal (158)	Pneumonia (427)
<i>Testing</i> (10%)	Normal (158)	Pneumonia (427)

2) Proses CLAHE

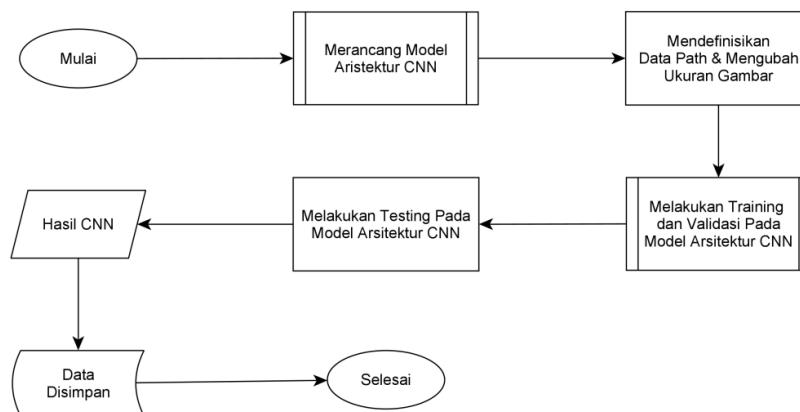


Gambar 5. Proses CLAHE

Gambar 5 merupakan alur proses penerapan CLAHE, pada proses ini citra yang sebelumnya memiliki format

BGR dirubah menjadi format $L^*a^*b^*$ yaitu dengan L^* sebagai indikator kecerahan, a^* sebagai indikator nilai merah/hijau, dan b^* sebagai indikator nilai biru/kuning. Berikutnya adalah melakukan konfigurasi terhadap parameter-parameter yang akan digunakan dalam menerapkan CLAHE, yaitu *clip limit* dan *region size*. Setelah dilakukan konfigurasi, CLAHE kemudian diterapkan pada *channel* L^* untuk meningkatkan kontras citra. Setelah CLAHE berhasil diterapkan, citra yang sebelumnya masih berbentuk format $L^*a^*b^*$ dirubah kembali kedalam format BGR.

D. Penerapan CNN



Gambar 6. Proses Penerapan CNN

Terdapat beberapa proses pada tahap ini, seperti yang dapat dilihat pada gambar 6 diatas. Proses pertama adalah melakukan perancangan terhadap arsitektur yang akan digunakan. Proses kedua adalah mendefinisikan data *path* dataset dan mengubah ukuran gambar sesuai dengan konfigurasi pada arsitektur CNN yang telah dirancang. Proses ketiga adalah melakukan *training* dan *validation* pada dataset yang telah dilakukan *preprocessing*. Kemudian proses berikutnya adalah melakukan pengujian terhadap model arsitektur CNN yang telah dilakukan *training* dan *validation*. Hasil pengujian ini selanjutnya disimpan untuk dilakukan evaluasi dan penyimpulan pada tahap berikutnya.

1) Perancangan Arsitektur CNN

Pada proses ini dilakukan perancangan terhadap model arsitektur CNN yang akan digunakan dalam penelitian. Terdapat berbagai parameter yang dapat dikonfigurasi sesuai keperluan dalam merancang model arsitektur. Parameter tersebut antara lain yaitu *Convolution Layer*, *Pooling Layer*, *Reshaping Layer*, *Core Layer*, *Metrics*, *Activation Layer*, *Losses*, dan *Optimizer*. Parameter-parameter ini diperoleh dari halaman *web* resmi keras [19], dimana parameter-parameter tersebut merupakan beberapa bagian dari banyaknya parameter yang dapat digunakan pada penerapan CNN dengan menggunakan keras.

2) Pengubahan Ukuran

Pada proses ini dilakukan perubahan ukuran pada citra *x-ray* toraks yang terdapat pada dataset. Hal ini dikarenakan citra yang terdapat pada dataset memiliki ukuran yang berbeda antara satu sama lain. Ukuran citra pada dataset kemudian dirubah menjadi beberapa ukuran kecil, yaitu 64x64px, 128x128px, dan 256x256px menyesuaikan dengan konfigurasi yang telah dibuat pada model arsitektur yang telah dirancang. Perubahan ukuran gambar menjadi beberapa ukuran kecil tersebut diterapkan untuk mengetahui pengaruh ukuran gambar terhadap *training accuracy*, *training loss*, *validation accuracy*, *validation loss* dan waktu *training* yang diperoleh.

3) Training dan Validation

Pada proses ini, model arsitektur yang telah dirancang pada proses sebelumnya dilakukan *training* dengan menggunakan data *training* dan dilakukan *validation* dengan menggunakan data *validation*. Proses *training* dan *validation* pada model ini dilakukan dengan beberapa jumlah *epoch* yang berbeda. Jumlah *epoch* yang berbeda tersebut nantinya akan digunakan untuk mengukur berapa jumlah *epoch* yang memperoleh hasil terbaik dan juga untuk mengukur performa model dalam melakukan pelatihan terhadap dataset dengan melihat nilai *training accuracy*, *training loss*, *validation accuracy* dan *validation loss* yang diperoleh. Jumlah *epoch* yang digunakan untuk melakukan *training* pada proses ini yaitu sebanyak 20 *epoch*, 40 *epoch*, 60 *epoch*, 80 *epoch*, 100 *epoch*, 120 *epoch*, 140 *epoch*, 160 *epoch*, 180 *epoch*, dan 200 *epoch*.

4) *Testing*

Pada proses ini model arsitektur CNN yang telah dilatih dan dilakukan validasi diuji dengan menggunakan data *testing*. Pengujian ini dilakukan untuk mengetahui tingkat keakuratan dari model arsitektur yang telah dibuat ketika melakukan klasifikasi. Dimana hasil akhir yang diperoleh pada proses *testing* ini akan digunakan sebagai acuan akurasi yang akan digunakan sebagai hasil akhir penelitian. Persamaan yang digunakan untuk mengukur tingkat akurasi yang diperoleh adalah sebagai berikut.

$$Akurasi = \frac{TN+TP}{FP+FN+TP+TN} \quad (1)$$

Keterangan:

True Positive (TP) : Klasifikasi citra normal diprediksi normal.

True Negative (TN) : Klasifikasi citra pneumonia diprediksi pneumonia.

False Positive (FP) : Klasifikasi citra pneumonia diprediksi normal.

False Negative (FN) : Klasifikasi citra normal diprediksi pneumonia.

E. *Evaluasi dan Kesimpulan*

Selanjutnya adalah tahap evaluasi dan pengambilan kesimpulan, pada tahap ini data-data hasil proses CNN yang telah diperoleh dilakukan analisis. Kemudian dalam melakukan analisis dilakukan pencatatan terhadap poin-poin penting yang terdapat pada tiap data tersebut. Poin-poin penting ini lalu digunakan sebagai dasar dalam melakukan penyimpulan akhir dari penelitian yang telah dilakukan.

III. HASIL DAN PEMBAHASAN

Setelah tahap-tahap pada metode penelitian telah selesai dilakukan diperoleh hasil-hasil penelitian sebagai berikut.

A. *Penerapan CLAHE*

Penerapan CLAHE dilakukan dengan tujuan untuk mengetahui pengaruh CLAHE terhadap hasil yang diperoleh model ketika dilakukan *training* dan *validation* serta dilakukan *testing*. Proses penerapan CLAHE ini dilakukan dengan menggunakan konfigurasi *ClipLimit* sebesar 1,0 dan *TileGrid (region size)* sebesar 8. Adapun tahapan penerapan CLAHE yang dilakukan sesuai dengan [20] adalah:

1. Gambar dibagi menjadi blok-blok berukuran 8x8 yang tidak saling tumpang tindih.
2. Dilakukan perhitungan histogram pada tiap blok.
3. Untuk peningkatan kontras pada tiap blok, batas *clip limit* histogram diatur menjadi 1,0.
4. Setelah dilakukan pemotongan nilai *threshold*, histogram didistribusikan kembali.
5. Setiap histogram blok diubah dengan menggunakan fungsi transformasi sebagai berikut.

$$A_t = \sum_{i=0}^t P_t(A_i) \quad (2)$$

dimana $P_t(A_i)$ merupakan fungsi kepadatan probabilitas dari nilai *grayscale* blok gambar *input* pada i dan didefinisikan sebagai berikut.

$$P_t(A_i) = \frac{m_i}{m} \quad (3)$$

dimana m_i merupakan nilai *grayscale* dari piksel *input* i , dan m merupakan jumlah total piksel dalam satu blok.

6. Interpolasi bilinear kemudian digunakan untuk menggabungkan blok-blok yang saling bersinggungan antara satu sama lain.

Setelah tahapan-tahapan tersebut selesai dilakukan, diperoleh contoh citra yang telah dilakukan penerapan CLAHE sebagai berikut.



Gambar 7. Citra Sebelum Dilakukan Penerapan CLAHE



Gambar 8. Citra Setelah Dilakukan Penerapan CLAHE

Seperti yang dapat dilihat pada gambar 7 dan gambar 8, terdapat perbedaan pada citra *x-ray* toraks setelah dilakukan penerapan CLAHE. Gambar 8 terlihat memiliki pencahayaan yang lebih tajam dibandingkan dengan

gambar 7. Hal ini dikarenakan gambar 7 telah dilakukan penerapan CLAHE sehingga kontras pada gambar telah berubah yang menyebabkan pencahayaan pada gambar 8 terlihat lebih tajam dibandingkan sebelumnya.

B. Arsitektur CNN

Model arsitektur yang dirancang pada penelitian ini menggunakan 4 *Convolution Layer* “Conv2D” dengan masing-masing menggunakan *Activation Layer* “ReLU”. Kemudian *Pooling Layer* yang digunakan adalah “Max Pooling” dengan jumlah *layer* sebanyak 4 yang dikonfigurasi beriringan setelah konfigurasi *layer* Conv2D ditetapkan. Berikutnya *Reshaping Layer* yang digunakan adalah “Flatten”, *layer* “Flatten” ini akan merubah *feature map* yang telah diperoleh pada proses konvolusi untuk selanjutnya diberikan kepada *layer* “Dense/Full Connected Layer” yang mana merupakan *Core Layer* yang digunakan. Pada “Dense Layer” ini juga terdapat *Activation Layer*, dimana *Activation Layer* yang digunakan tersebut adalah “Softmax”, yang kemudian “Softmax” akan bertindak sebagai *classifier* dan akan menentukan hasil akhir klasifikasi.

Selanjutnya untuk memperoleh nilai hasil proses *training* yang dilakukan pada model, “categorical_crossentropy” digunakan sebagai *Losses* yang digunakan untuk memperoleh nilai *loss*, sedangkan “Accuracy” digunakan sebagai *Metrics* yang digunakan untuk memperoleh nilai akurasi pada model. Selain itu “Adam” juga digunakan sebagai *Optimizer* agar model dapat memperoleh hasil yang lebih baik dalam melakukan proses *training*. *Summary* model arsitektur yang telah dirancang dapat dilihat pada gambar 9 sebagai berikut.

```
Model: "sequential"
-----
```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 32)	896
max_pooling2d (MaxPooling2D)	(None, 127, 127, 32)	0
conv2d_1 (Conv2D)	(None, 125, 125, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 64)	0
conv2d_2 (Conv2D)	(None, 60, 60, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(None, 30, 30, 64)	0
conv2d_3 (Conv2D)	(None, 28, 28, 128)	73856
max_pooling2d_3 (MaxPooling2D)	(None, 14, 14, 128)	0
flatten (Flatten)	(None, 25088)	0
dense (Dense)	(None, 2)	50178

```
-----
Total params: 180,354
Trainable params: 180,354
Non-trainable params: 0
```

Gambar 9. *Summary* Arsitektur CNN Dengan Input Ukuran 256x256

C. Epoch

Hasil proses *training* dan *validation* yang dilakukan dengan jumlah *epoch* yang berbeda-beda menunjukkan bahwa *epoch* mempengaruhi akurasi yang diperoleh. Hal tersebut dapat dilihat dari beragamnya nilai hasil *training* dan *validation* model. Dimana pada beberapa *epoch* model dapat memperoleh nilai akurasi yang baik, sedangkan pada beberapa *epoch* lainnya model tidak dapat memperoleh nilai akurasi yang baik. Hasil perolehan *training* dan *validation* terbaik dan terburuk pada model dapat dilihat sebagai berikut.


TABEL II
HASIL PEROLEHAN TRAINING DAN VALIDATION TERBAIK

Tanpa Penerapan CLAHE					
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss
64x64	100	0,96875	0,071736	0,93750	0,173682
128x128	180	1,00000	0,038806	0,96875	0,044989
256x256	180	0,93750	0,091013	0,93750	0,230705
Dengan Penerapan CLAHE					
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss
64x64	180	0,93750	0,140072	1,00000	0,031299
128x128	200	0,96875	0,089892	1,00000	0,034215
256x256	100	1,00000	0,062025	1,00000	0,005370


TABEL III
HASIL PEROLEHAN TRAINING DAN VALIDATION TERBURUK

Tanpa Penerapan CLAHE					
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss
64x64	40	0,75000	0,823253	0,71875	0,534574
128x128	20	0,75000	0,494202	0,75000	0,588446
256x256	20	0,87500	0,345757	0,31250	1,294140
Dengan Penerapan CLAHE					
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss
64x64	20	0,62500	0,693647	0,75000	0,732999
128x128	20	0,81250	0,372191	0,75000	0,502091
256x256	20	0,75000	0,525785	0,71875	0,562585

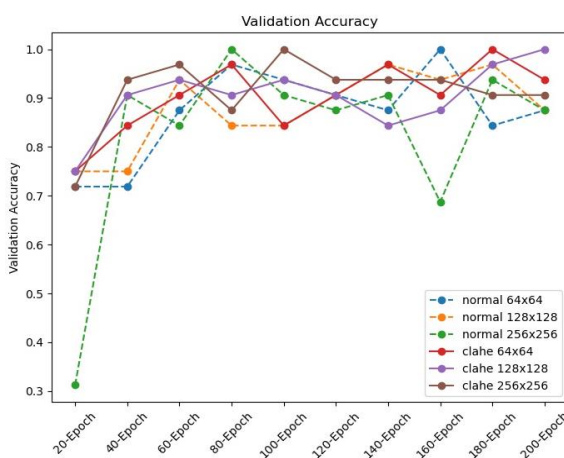
Dapat dilihat pada tabel II dan tabel III, diketahui bahwa model dengan *epoch* 100, 180, dan 200 memperoleh akurasi terbaik. Sebaliknya model dengan *epoch* 20 dan 40 memperoleh akurasi terburuk. Berdasarkan hal tersebut dapat diketahui bahwa semakin banyak *epoch* yang digunakan belum tentu membuat model dapat memperoleh hasil yang semakin baik, namun semakin sedikit *epoch* yang digunakan maka perolehan hasil model akan semakin buruk. Hal ini dikarenakan seperti yang dapat dilihat pada kedua tabel tersebut, model juga berhasil memperoleh akurasi terbaik pada *epoch* 100 dan 180, dimana kedua *epoch* tersebut merupakan *epoch* yang lebih sedikit dari *epoch* terbanyak yang digunakan yaitu *epoch* 200. Sebaliknya perolehan hasil terburuk terbanyak terdapat pada *epoch* 20, dimana *epoch* 20 merupakan *epoch* terkecil yang digunakan. Grafik perolehan keseluruhan *training* dan *validation* dapat dilihat pada gambar 10, gambar 11, gambar 12, dan gambar 13 sebagai berikut.




Gambar 20. Grafik Training Accuracy



Gambar 31. Grafik Training Loss



Gambar 42. Grafik Validation Accuracy



Gambar 53. Grafik Validation Loss

D. Rata-Rata Hasil

Untuk mengetahui dengan lebih baik model mana yang memperoleh hasil terbaik antara model yang diterapkan dataset dengan penerapan CLAHE dan tidak. Dilakukan perhitungan rata-rata terhadap hasil yang diperoleh masing-masing model. Hasil perhitungan rata-rata yang diperoleh pada masing-masing model dapat dilihat pada

gambar 14 dan gambar 15 sebagai berikut.


	Ukuran	Train Acc	Train Loss	Val Acc	Val Loss	Test Acc
0	64x64	0.893750	0.276500	0.871875	0.272593	0.892821
1	128x128	0.918750	0.208587	0.878125	0.251880	0.889231
2	256x256	0.903125	0.251358	0.825000	0.419178	0.842222

Gambar 64. Hasil Rata-Rata Model Tanpa Penerapan CLAHE

	Ukuran	Train Acc	Train Loss	Val Acc	Val Loss	Test Acc
0	64x64	0.893750	0.240632	0.903125	0.257317	0.898803
1	128x128	0.943750	0.150807	0.903125	0.216530	0.912991
2	256x256	0.915625	0.228744	0.912500	0.219259	0.915556

Gambar 75. Hasil Rata-Rata Model Dengan Penerapan CLAHE

Terlihat bahwa nilai hasil perhitungan rata-rata yang diperoleh model dengan dataset yang dilakukan penerapan CLAHE memperoleh hasil yang lebih baik dari pada model dengan dataset yang tidak dilakukan penerapan CLAHE. Hal tersebut dapat diketahui dengan lebih baik setelah data-data hasil perolehan model diterapkan kedalam grafik-grafik yang dapat dilihat pada gambar 16 sebagai berikut.





Gambar 86. Grafik Rata-rata perolehan *Training*, *Validation*, dan *Testing*



Berdasarkan grafik-grafik tersebut terlihat jelas bahwa model dengan dataset yang dilakukan penerapan CLAHE memperoleh hasil yang lebih unggul dari pada model dengan dataset yang tidak dilakukan penerapan CLAHE. Dimana model berhasil mengungguli perolehan rata-rata hasil yang diperoleh pada keseluruhan aspek, yaitu *training accuracy*, *training loss*, *validation accuracy*, *validation loss*, dan *testing accuracy*.

E. Ukuran

Beberapa ukuran gambar yang berbeda diterapkan pada model untuk mengetahui pengaruh ukuran gambar terhadap *training accuracy*, *training loss*, *validation accuracy*, *validation loss*, dan lama waktu *training* yang diperoleh. Beberapa ukuran gambar yang berbeda-beda ini antara lain berukuran 64x64px, 128x128px, dan 256x256px. Dimana kemudian hasil-hasil yang diperoleh pada masing-masing ukuran gambar tersebut selanjutnya dilakukan analisis guna mengetahui ukuran gambar manakah yang memperoleh hasil perolehan terbaik. Analisis perolehan hasil ini dilakukan dengan melakukan perhitungan rata-rata terhadap seluruh perolehan hasil masing-masing ukuran gambar yang dapat dilihat sebagai berikut.

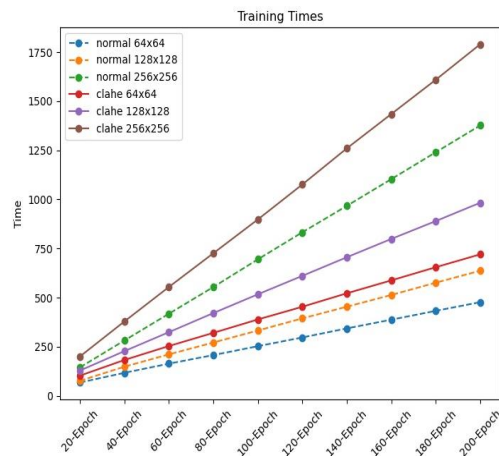
Gambar 97. Grafik Rata-rata *Training Accuracy*Gambar 108. Grafik Rata-rata *Training Loss*

Seperti yang dapat dilihat pada gambar 17 di atas dapat dilihat bahwa ukuran gambar 128x128px memperoleh hasil rata-rata akurasi terbaik pada *training accuracy*, dimana model dengan penerapan CLAHE memperoleh nilai rata-rata akurasi sebesar 0,9437 dan model yang tidak dilakukan penerapan CLAHE memperoleh nilai rata-rata akurasi sebesar 0,9187. Kemudian pada gambar 18, ukuran gambar 128x128px juga memperoleh hasil rata-rata yang lebih baik pada *validation accuracy*, dimana model dengan penerapan CLAHE berhasil memperoleh nilai rata-rata akurasi sebesar 0,9031 dan model yang tidak dilakukan penerapan CLAHE memperoleh nilai rata-rata akurasi sebesar 0,8781. Namun meskipun nilai rata-rata akurasi *validation accuracy* tertinggi diperoleh ukuran 256x256px pada model dengan penerapan CLAHE, tetapi model yang tidak dilakukan penerapan CLAHE memperoleh hasil nilai rata-rata akurasi terendah sehingga hal tersebut menunjukkan bahwa ukuran gambar 128x128px memperoleh nilai rata-rata akurasi yang lebih baik.

Gambar 19. Grafik Rata-rata *Validation Accuracy*Gambar 20. Grafik Rata-rata *Validation Loss*

Selain itu pada gambar 19 dan gambar 20 di atas, terlihat bahwa ukuran gambar 128x128px memperoleh nilai rata-rata *loss* terkecil dibandingkan ukuran gambar lainnya. Pada *training loss*, model dengan penerapan CLAHE memperoleh nilai rata-rata *loss* sebesar 0,1508, sedangkan model dengan tanpa penerapan CLAHE memperoleh nilai rata-rata *loss* sebesar 0,2086. Berikutnya pada *validation loss*, model dengan penerapan CLAHE memperoleh nilai rata-rata *loss* sebesar 0,2165, dan model dengan tanpa penerapan CLAHE memperoleh nilai rata-rata *loss* sebesar 0,2519.


Dengan demikian berdasarkan hasil-hasil perolehan tersebut dapat diketahui bahwa ukuran 128x128px berhasil memperoleh nilai rata-rata yang lebih baik dari ukuran 64x64px dan 256x256px pada *training accuracy*, *validation accuracy*, *training loss*, dan *validation loss* yang diperoleh. Selain itu berdasarkan grafik perolehan lama waktu *training* yang dapat dilihat pada gambar 21 di bawah. Terlihat bahwa semakin besar ukuran gambar maka semakin lama waktu yang diperlukan untuk melakukan *training*, dimana gambar yang dilakukan penerapan CLAHE membutuhkan waktu *training* yang lebih lama dari pada gambar yang tidak dilakukan penerapan CLAHE. Hal tersebut menunjukkan bahwa ukuran gambar berpengaruh terhadap lama waktu *training* yang diperoleh.



Gambar 21. Grafik Waktu Training

F. Hasil Terbaik

Pengujian dilakukan untuk mengetahui tingkat keakuratan model dalam melakukan klasifikasi, dimana kemudian nilai akurasi tersebut digunakan sebagai acuan dalam menentukan model yang memperoleh akurasi pengujian terbaik. Setelah pengujian pada masing-masing model dilakukan, diperoleh grafik akurasi pengujian yang dapat dilihat pada gambar 22 berikut.



Gambar 22. Grafik Akurasi Pengujian

Dapat dilihat bahwa akurasi pengujian yang diperoleh pada masing-masing model cukup beragam. Selanjutnya untuk mengetahui model manakah yang memperoleh hasil akurasi pengujian terbaik, hasil-hasil perolehan pengujian pada masing-masing model tersebut kemudian dipilih dan diterapkan pada tabel IV sebagai berikut.

TABEL IV
HASIL PEROLEHAN PENGUJIAN TERBAIK

Tanpa Penerapan CLAHE						
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss	Test Acc
64x64	200	0,96875	0,096634	0,87500	0,259239	0,947009
128x128	160	1,00000	0,078738	0,93750	0,157121	0,943590
256x256	180	0,93750	0,091013	0,93750	0,230705	0,945299
Dengan Penerapan CLAHE						
Ukuran	Epoch	Train Accuracy	Train Loss	Val Accuracy	Val Loss	Test Acc
64x64	200	0,93750	0,128038	0,93750	0,173539	0,952137
128x128	200	0,96875	0,089892	1,00000	0,034215	0,943590
256x256	180	0,93750	0,102037	0,90625	0,145477	0,952137

Berdasarkan perolehan hasil pengujian model tersebut, dapat diketahui bahwa model dengan penerapan CLAHE pada ukuran 256x256 memperoleh hasil pengujian terbaik diantara model yang lainnya. Dimana model berhasil memperoleh nilai *testing accuracy* tertinggi sebesar 0,952137 pada *epoch* 180, dengan *training accuracy* sebesar 0,93750, *training loss* sebesar 0,102037, *validation accuracy* sebesar 0,90625, dan *validation loss* sebesar

0,145477.

IV. KESIMPULAN

Berdasarkan hasil-hasil perolehan penerapan CLAHE dan CNN serta analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut.

- 1) Dataset yang dilakukan penerapan CLAHE memperoleh hasil yang lebih baik dari pada dataset yang tidak dilakukan penerapan CLAHE. Hal ini dapat dilihat dari rata-rata perolehan hasil yang diperoleh dataset yang diterapkan CLAHE lebih unggul dari dataset yang tidak diterapkan CLAHE pada keseluruhan aspek yaitu *training accuracy*, *training loss*, *validation accuracy*, *validation loss*, dan *testing accuracy*.
- 2) Jumlah *epoch* berpengaruh terhadap *training accuracy*, *training loss*, *validation accuracy*, dan *validation loss* yang diperoleh, dimana semakin banyak *epoch* yang digunakan belum tentu membuat model dapat memperoleh hasil yang semakin baik, namun semakin sedikit *epoch* yang digunakan maka perolehan hasil model akan semakin buruk. Hal ini dikarenakan pada beberapa kasus *epoch* terbanyak memperoleh akurasi lebih rendah dari pada *epoch* yang lebih sedikit, sedangkan *epoch* terkecil paling banyak memperoleh nilai akurasi terendah.
- 3) Ukuran gambar berpengaruh terhadap *training accuracy*, *training loss*, *validation accuracy*, *validation loss*, dan waktu *training* yang diperoleh. Hal tersebut dapat diketahui berdasarkan perolehan rata-rata hasil masing-masing ukuran, dimana ukuran gambar 128x128px memperoleh tingkat perolehan hasil yang lebih baik dari ukuran gambar lainnya. Selain itu ukuran gambar juga mempengaruhi waktu *training*, hal ini dikarenakan semakin besar ukuran gambar yang digunakan maka semakin lama waktu *training* yang dibutuhkan.
- 4) Model dengan penerapan CLAHE pada *epoch* 180 dengan ukuran 256x256 memperoleh perolehan hasil pengujian terbaik dari keseluruhan model dengan perolehan *testing accuracy* sebesar 95,21%, *training accuracy* sebesar 93,75%, *training loss* sebesar 0,102037, *validation accuracy* sebesar 90,62%, dan *validation loss* sebesar 0,145477.

DAFTAR PUSTAKA

- [1] "Pneumonia," *World Health Organization*, 2019. <https://www.who.int/news-room/fact-sheets/detail/pneumonia> (accessed May 20, 2020).
- [2] S. Naveed *et al.*, "Awareness about Pneumonia Research," *J. Biotechnol. Biosaf.*, vol. 3, no. 3, pp. 260–264, 2015.
- [3] J. Müller, "Number of pneumonia cases in Indonesia from 2012 to 2018," *Statista*, 2020. <https://www.statista.com/statistics/705161/number-of-pneumonia-cases-in-indonesia/> (accessed May 20, 2020).
- [4] "Deaths from pneumonia, by age, Indonesia, 1990 to 2017," *Our World in Data*. <https://ourworldindata.org/grapher/pneumonia-and-lower-respiratory-diseases-deaths?country=-IDN> (accessed Jan. 13, 2021).
- [5] A. D. Susanto, "Pers Release Perhimpunan Dokter Paru Indonesia dalam rangka WORLD PNEUMONIA DAY 2018," *PERHIMPUNAN DOKTER PARU INDONESIA*, 2018. <https://www.klikpdpi.com/index.php?mod=article&sel=8704> (accessed Jun. 15, 2020).
- [6] S. Waite, J. Scott, B. Gale, T. Fuchs, S. Kolla, and D. Reede, "Interpretive error in radiology," *Am. J. Roentgenol.*, vol. 208, no. 4, pp. 739–749, 2017, doi: 10.2214/AJR.16.16963.
- [7] I. W. S. E. P, A. Y. Wijaya, and R. Soelaiman, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, pp. A65–A69, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [8] R. Rokhiana *et al.*, "Convolutional Neural Network untuk Pendeteksian Patah Tulang Femur pada Citra Ultrasonik B–Mode," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 1, pp. 59–67, 2019, doi: 10.22146/jnteti.v8i1.491.
- [9] Felix, S. Faisal, T. F. M. Butarbutar, and P. Sirait, "Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun," *J. SIFO Mikroskil*, vol. 20, no. 2, pp. 117–134, 2019.
- [10] A. Ramdan, V. Zilvan, E. Suryawati, H. F. Pardede, and V. P. Rahadi, "Klasifikasi klon teh berbasis deep CNN dengan residual dan densely connections," *J. Teknol. dan Sist. Komput.*, vol. 8, no. 4, pp. 289–296, 2020, doi: 10.14710/jtsiskom.2020.13768.
- [11] O. Stephen, M. Sain, U. J. Maduh, and D. U. Jeong, "An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare," *J. Healthc. Eng.*, vol. 2019, 2019, doi: 10.1155/2019/4180949.
- [12] M. N. Aziz, T. W. Purboyo, and A. L. Prasasti, "A Survey on the Implementation of Image Enhancement," *Int. J. Appl. Eng. Res.*, vol. 12, no. 21, pp. 11451–11459, 2017.
- [13] P. Musa, F. Al Raf, and M. Lamsani, "A review: Contrast-limited adaptive histogram equalization (CLAHE) methods to help the application of face recognition," *Proc. 3rd Int. Conf. Informatics Comput. ICIC 2018*, no. November 2020, pp. 1–6, 2018, doi: 10.1109/IAC.2018.8780492.
- [14] R. K. Hapsari, M. I. Utoyo, R. Rulaningtyas, and H. Suprajitno, "Comparison of Histogram Based Image Enhancement Methods on Iris Images," *J. Phys. Conf. Ser.*, vol. 1569, no. 2, 2020, doi: 10.1088/1742-6596/1569/2/022002.
- [15] A. A. Riadi, A. A. Chamid, and A. Sokhibi, "Analisis Komparasi Metode Perbaikan Kontras Berbasis Histogram Equalization Pada Citra Medis," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 8, no. 1, pp. 383–388, 2017, doi: 10.24176/simet.v8i1.1026.
- [16] M. M. Sebatubun, "Peningkatan Kualitas Citra X-Ray Paru-Paru Menggunakan Contrast Limited Adaptive Histogram Equalization dan Gaussian Filter," *Semin. Ris. Teknol. Inf.*, pp. 241–247, 2016.
- [17] Nurhidayah, B. Abdul Samad, and B. Abdullah, "Perbandingan Metode Contrast Enhancement pada Citra CT-Scan Kanker Paru-paru," *Gravitasi*, vol. 19, no. 2, pp. 24–28, 2020, doi: 10.22487/gravitasi.v19i2.15360.
- [18] D. S. Kermany *et al.*, "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, vol. 172, no. 5, pp. 1122–1131, 2018, doi: 10.1016/j.cell.2018.02.010.
- [19] "Keras API reference," *Keras*. <https://keras.io/api/> (accessed Jun. 20, 2021).
- [20] M. M. Jadoon, Q. Zhang, I. U. Haq, S. Butt, and A. Jadoon, "Three-Class Mammogram Classification Based on Descriptive CNN Features," *Biomed Res. Int.*, vol. 2017, 2017, doi: 10.1155/2017/3640901.