

KLASIFIKASI PNEUMONIA PADA AUGMENTASI CITRA X-RAY PARU-PARU MENGGUNAKAN METODE CONVOLUTION NEURAL NETWORK (CNN)

[CLASSIFICATION OF PNEUMONIA ON AUGMENTED CHEST X-RAY IMAGES USING CONVOLUTIONAL NEURAL NETWORK (CNN) METHOD]

Ahdiat Aunul Hipzi¹, Giri Wahyu Wiriasto², I Made Budi Suksmadana³

^{1,3}Jurusan Teknik Elektro Universitas Mataram
Jl. Majapahit no. 62, Mataram, NTB, INDONESIA

¹ahdiats542@gmail.com, ²giriwahyuwiriasto@unram.ac.id, ³mdbudisuk@unram.ac.id

ABSTRAK

Pneumonia merupakan peradangan paru-paru yang disebabkan oleh infeksi virus, bakteri, atau jamur. Menurut WHO pada tahun 2018 pneumonia mengakibatkan kematian terhadap anak balita sebanyak 800.000 orang di dunia, atau 39 orang anak per detik. Untuk mengurangi tingginya angka kematian tersebut, perlu dilakukan pengendalian dengan cara mendiagnosa pneumonia kepada pasien dengan cepat. Pada penelitian ini, klasifikasi pneumonia dilakukan melalui citra X-Ray paru-paru menggunakan metode Convolutional Neural Network (CNN). Tujuan dari penelitian ini untuk memperoleh model CNN dengan nilai akurasi yang tinggi dalam klasifikasi pneumonia. Dataset yang digunakan berjumlah 7.442 citra, Model CNN yang dibuat memiliki 5 konvolusi dengan jumlah channel/kernel 16, 32, 64, 128, dan 128 serta 3 hidden layer. Training model menggunakan adam optimizer dan ukuran input 200x200x1 sedangkan fungsi aktivasi menggunakan ReLU dan Sigmoid. Hasil pengujian model CNN mendapatkan nilai akurasi sebesar 96,64% untuk training dan 95,36% untuk validating. Model CNN dapat dikatakan mampu untuk mengklasifikasi suatu citra X-Ray paru-paru termasuk kategori pneumonia atau normal.

Kata kunci : Pneumonia, citra X-Ray, klasifikasi, convolutional neural network.

ABSTRACT

Pneumonia is an inflammation of the lungs caused by viral, bacterial, or fungal infections. According to WHO, in 2018, pneumonia resulted in the deaths of 800,000 infants worldwide, equivalent to 39 child deaths per second. To reduce the high mortality rate, it is necessary to control pneumonia by quickly diagnosing it in patients. In this study, pneumonia classification is performed on chest X-ray images using Convolutional Neural Network (CNN) method. The goal of this research is to obtain a CNN model with high accuracy in pneumonia classification. The dataset used consists of 7,442 images. The CNN model includes 5 convolutional with channel/kernel sizes of 16, 32, 64, 128, and 128, as well as 3 hidden layers. The model is trained using adam optimizer and the input size is 200x200x1. The activation functions used are ReLU and Sigmoid. The testing of the CNN model resulted in an accuracy of 96.64% for training and 95.36% for validation. The CNN model can be considered capable of classifying a chest X-ray image into either the pneumonia or normal category.

Keywords: Pneumonia, X-Ray image, classification, convolutional neural network.

PENDAHULUAN

Pneumonia merupakan peradangan pada paru-paru yang disebabkan oleh infeksi virus, bakteri, atau jamur. Seseorang yang mengalami pneumonia, kantong udara pada paru-parunya akan berisi cairan maupun pus (dahak purulen). Menurut WHO pada tahun 2019, pneumonia merenggut nyawa 740.180

anak dibawah usia 5 tahun di seluruh dunia, terhitung 14% kematian anak dibawah 5 tahun disebabkan oleh pneumonia. Pada tahun 2018, berdasarkan data UNICEF diperkirakan sekitar 19.000 anak meninggal akibat pneumonia. Estimasi global menunjukkan bahwa satu jam ada 71 anak di Indonesia yang tertular pneumonia. Hal ini menunjukkan bahwa pneumonia merupakan salah satu jenis

penyakit yang menyebabkan tingginya angka kematian di dunia. Untuk mengurangi tingginya angka kematian yang diakibatkan oleh penyakit pneumonia maka perlu dilakukan pengendalian yang salah satu caranya dengan melakukan pengobatan kepada pasien secara cepat dan tepat.

Perkembangan teknologi pada zaman sekarang ini cukup pesat setiap tahunnya. Bahkan ilmu teknologi telah dimanfaatkan oleh manusia dalam segala bidang kehidupannya termasuk dalam bidang kesehatan. *Image Classification* atau pengklasifikasian gambar merupakan teknologi komputer yang berkaitan dengan *computer vision* dan *image processing* yang berhubungan dengan pengkategorian suatu gambar citra digital yang dapat berupa warna dan bentuk objek kedalam suatu kategori tertentu.

Berdasarkan uraian tersebut, penulis membuat sistem pengenalan gambar atau objek sehingga dapat mendiagnosis penyakit pneumonia berdasarkan citra X-ray paru-paru menggunakan metode *Convolutional Neural Network* (CNN) yang memiliki tingkat akurasi yang relatif tinggi dan mendapatkan hasil yang signifikan dalam pengenalan citra digital. Penelitian ini diharapkan dapat mengurangi waktu dan menjadi tinjauan para dokter dalam mendiagnosis penyakit pneumonia pada pasien melalui hasil gambar X-ray paru-paru.

Pneumonia

Secara klinis pneumonia didefinisikan sebagai suatu peradangan parenkim paru distal dari bronkiolus terminalis yang mencakup bronkiolus respiratorius dan alveoli serta menimbulkan konsolidasi jaringan paru dan gangguan pertukaran gas setempat (Sudoyo, 2005). pneumonia j dapat diklasifikasikan berdasarkan area paru yang terinfeksi (lobar pneumonia, multilobar pneumonia, bronchial pneumonia, dan interstitial pneumonia) atau agen kausatif (Pane, 2020).

Klasifikasi Citra

Klasifikasi citra merupakan sebuah pekerjaan untuk memasukkan sebuah citra dan menetapkannya ke sebuah kategori. Ini adalah salah satu permasalahan dalam *Computer Vision* yang dapat disederhanakan dan memiliki berbagai macam aplikasinya. Salah

satu aplikasi dalam klasifikasi citra adalah pengklasifikasian nama tempat pada suatu citra (Danukusumo, 2017).

Deep Learning


Deep Learning (DL) merupakan salah satu bidang dari *Machine Learning* yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *Deep Learning* memberikan arsitektur yang sangat kuat untuk *Supervised Learning*. Dengan menambahkan lebih banyak lapisan maka model pembelajaran tersebut bisa mewakili data citra berlabel dengan lebih baik (Danukusumo, 2017).

Computer Vision

Computer Vision merupakan salah satu cabang ilmu pengetahuan yang bertujuan untuk membuat suatu keputusan yang berguna untuk mengenali objek fisik nyata dan keadaan berdasarkan sebuah gambar atau citra (Shapiro & Stockman, 2001). *Computer Vision* menjadikan komputer “*acts like human sight*”, sehingga mendekati kemampuan manusia dalam menangkap informasi visual.

Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu bagian dari *Deep Learning* yang telah membawa terobosan dibidang *pattern recognition of images*. CNN menunjukkan kinerja yang tinggi dalam pengklasifikasian gambar secara alami sehingga dapat memberikan pengaruh besar terhadap berbagai aspek dalam kehidupan terutama dibidang kesehatan (Widodo dkk, 2020). Pada CNN setiap neuron dipresentasikan dalam bentuk 2 dimensi, sehingga metode ini cocok untuk pemrosesan dengan *input* berupa citra. Arsitektur jaringan dengan menggunakan CNN ditunjukkan pada Gambar 1. Struktur CNN terdiri dari *input*, proses ekstraksi fitur, proses klasifikasi dan *output* (Arrofiqoh dkk, 2018).




Gambar 1. Arsitektur jaringan menggunakan CNN

Preprocessing

Preprocessing adalah proses awal dilakukannya perbaikan suatu data citra untuk menghilangkan noise sebelum data citra tersebut diolah. Preprocessing merupakan suatu proses untuk menghilangkan bagian-bagian yang tidak diperlukan pada gambar input untuk proses selanjutnya. Beberapa proses yang dapat dilakukan pada tahap *preprocessing* antara lain, proses *rescale*, *resize*, dan *grayscale* (Bahri dan maliki, 2012).

Augmentation Data

Augmentasi data adalah strategi yang memungkinkan praktisi untuk secara signifikan meningkatkan keragaman data yang tersedia untuk model pelatihan, tanpa benar-benar mengumpulkan data baru. Teknik augmentasi data seperti *cropping*, *padding*, dan *flipping horizontal* umumnya digunakan untuk melatih jaringan neural besar. Namun, sebagian besar pendekatan yang digunakan dalam pelatihan jaringan neural hanya menggunakan tipe augmentasi dasar. Sementara arsitektur jaringan neural telah diselidiki secara mendalam (Sanjaya, 2020). Contoh augmentasi data terhadap gambar dapat dilihat pada Gambar 2.



Gambar 2. Contoh Augmentation Data Citra

Fungsi Aktivasi

Dalam permodelan jaringan saraf tiruan, fungsi aktivasi digunakan untuk menentukan hasil keluaran suatu *neuron* pada setiap layer. Salah satu fungsi aktivasi yang biasa digunakan dalam jaringan saraf tiruan adalah *sigmoid* dan

Rectified Lunear Unit (ReLU). Fungsi *Sigmoid* mentransformasi range nilai dari input *x* menjadi antara 0 dan 1 (Putra, 2015).. Fungsi sigmoid dapat dilihat pada persamaan (1) berikut:


$$\sigma(x) = \frac{1}{(1+e^{-x})} \dots\dots\dots(1)$$

Fungsi ReLU termasuk salah satu fungsi aktivasi baru yang menjadi populer bersamaan dengan kemunculan CNN modern. Fungsi ReLU melakukan operasi thresholding nilai linear pada nol. Secara matematis fungsi ReLU memiliki bentuk pada persamaan (2) sebagai berikut:

$$\sigma(x) = \max(0, x) \dots\dots\dots(2)$$

Dropout Regularization

Dropout Regularization adalah teknik untuk mengaktifkan sebagian neuron dalam *hidden layer* dan menonaktifkan sebagian yang lain. Tujuannya agar model tidak terjebak didalam *overfitting* (Saputra dan Ajeng, 2022). Neuron yang akan dinonaktifkan akan dipilih secara acak dimana setiap neuron akan diberikan probabilitas yang bernilai antara 0 dan 1. Untuk jelasnya, bisa dilihat pada Gambar 3:



Gambar 3. Ilustrasi proses dropout regularization

Adam Optimizer

Adam optimizer merupakan suatu cara untuk mengoptimasi suatu parameter, optimasi tersebut dapat membuat parameter menjadi maksimum atau minimum. Adam Optimizer adalah salah satu optimasi yang menggabungkan metode AdaGrad dan

RMSProp (Hakim dan Rainarli, 2019). Adapun tahapan adam optimizer dalam melakukan optimasi yaitu sebagai berikut:

- a) Menambah t pada setiap iterasi.

$$t = t + 1 \dots\dots\dots(3)$$

- b) Menghitung gradien.

$$g_t = \nabla_{\theta} f_t(\theta_{t-1}) \dots\dots\dots(4)$$

- c) Memperbaharui bias momen pertama.

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \dots\dots\dots(5)$$

- d) Memperbaharui bias momen kedua.

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \dots\dots\dots(6)$$

- e) Menghitung koreksi bias momen pertama.

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t} \dots\dots\dots(7)$$

- f) Menghitung koreksi bias momen kedua.

$$\widehat{v}_t = \frac{v_t}{1 - \beta_2^t} \dots\dots\dots(8)$$

- g) Memperbaharui parameter.

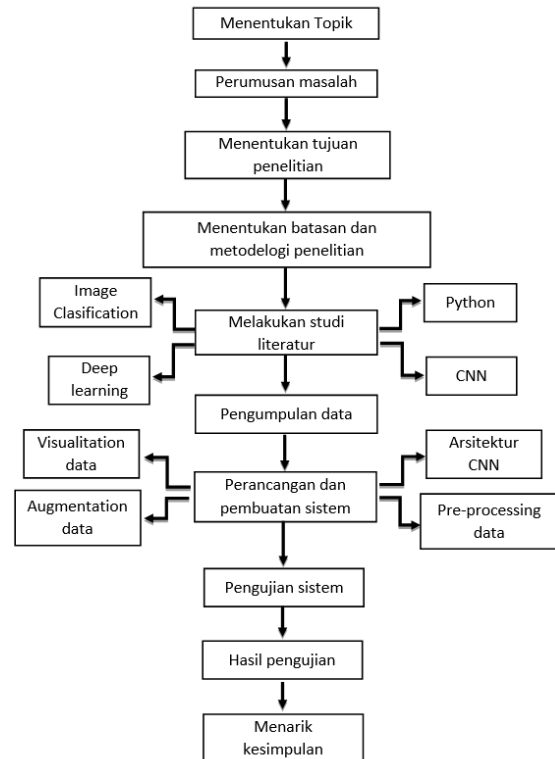
$$\theta_t = \theta_{t-1} - \frac{\alpha \cdot \widehat{m}_t}{\sqrt{\widehat{v}_t} + \epsilon} \dots\dots\dots(9)$$

METODELOGI PENELITIAN

Metodelogi penelitian berisi uraian tentang alat-alat dan bahan yang digunakan dalam penelitian ini. Selain itu, tahapan atau tata pelaksanaan penelitian, metode pelatihan citra digital, algoritma penelitian dan rencana pengolahan atau analisis hasil dijelaskan juga pada bagian ini.

Tahapan penelitian

Tahapan atau langkah-langkah penelitian yang dilakukan pada penelitian ini dapat dilihat pada Gambar 4. diagram blok berikut:



Gambar 4. Diagram blok tahapan penelitian

Alat-alat yang digunakan

Alat-alat yang digunakan terdiri dari perangkat keras (*hardware*) yaitu; laptop MSI type GF63 dengan spesifikasi processor Intel Core i7-9750H CPU, RAM 8 GB, Hardisk penyimpanan SSD 500 GB, dan VGA NVIDIA GeForce GTX 1650 2.147 MB (2 GB). Selain itu, menggunakan perangkat lunak dalam melakukan proses pengujian berupa, sistem Operasi Windows 10 Home 64 bit versi 20H2, PyCharm versi 211.7442.45, Python 3.9.5, OpenCV liblary versi 4.5.2, TensorFlow liblary versi 2.7.0, dan Matplotlib liblary versi 3.5.1.

Jenis dan sumber data

Jenis data yang digunakan pada penelitian ini adalah data sekunder berupa dataset citra dua dimensi atau gambar. Dataset yang digunakan berasal dari dua buah dataset yang diambil dari website Kaggle. Dataset pertama merupakan citra X-ray paru-paru (anterior-posterior) dipilih dari kohort retrospektif pasien anak-anak berusia satu hingga lima tahun dari Pusat Medis Wanita dan Anak Guangzhou,

Guangzhou. Dataset kedua merupakan repositori terintegrasi dari limabelas dataset lainnya yang dikumpulkan oleh empat institut yaitu Indian Institute of Science, PES University, M S Ramaiah Institute of Technology, dan Concordia University.

Dataset

Dataset yang digunakan adalah gabungan dari dua dataset yang berisi kumpulan citra X-ray paru-paru keseluruhan berjumlah 7.442 gambar citra. Ukuran bentuk gambar pada dataset bervariasi mulai dari 710 x 430 pixel sampai ukuran 2720 x 2460 pixel. Dataset dibagi menjadi dua yaitu data latih dan data test. Data latih berjumlah 7.242 citra sedangkan untuk data test berjumlah 200 citra. Data latih dibagi lagi menjadi dua bagian untuk data citra pelatihan dan data citra validasi dengan perbandingan delapan banding dua (8:2). Contoh citra dataset seperti pada Gambar 5. (a) dan (b).



(a) Normal (b) Pneumonia

Gambar 5. (a) dan (b) contoh citra tiap kelas

Preprocessing

preprocessing merupakan tahap pengolahan citra yang bertujuan untuk mendapatkan kualitas citra yang lebih baik dengan cara memanipulasi parameter-parameter citra. Tahapan preprocessing ini terdiri dari *Grayscale*, *Rescale*, dan *Resize*.


Augmentation data

Augmentation data merupakan teknik memperbanyak data citra dengan menerapkan transformasi pada data citra asli. Pada tahap ini dilakukan lima proses transformasi data citra sebagai berikut:

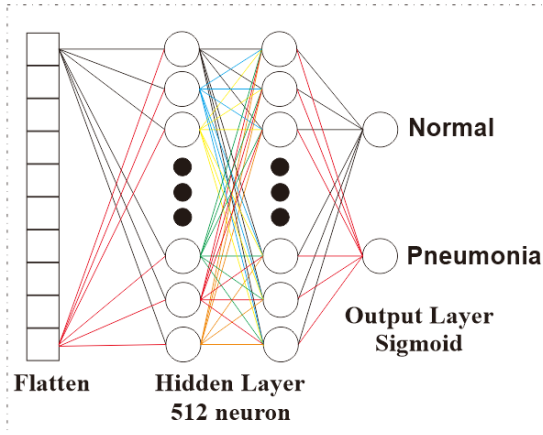
- Rotation Range* merupakan proses pemutaran data citra secara acak. Pada penelitian ini range perputaran citra adalah 30° .
- Zoom Range* merupakan transformasi gambar citra dengan memperbesar bentuk ukuran gambar secara acak. Besar *zoom range* yang dilakukan pada penelitian ini adalah 20% dari data citra asli.
- Width Shift Range* merupakan proses menggeser acak data citra asli secara horizontal. Besar pergeseran yang digunakan dalam penelitian ini adalah 10%.
- Height Shift Range* merupakan pergeseran data citra asli secara acak dengan arah ke atas maupun kebawah atau vertikal. Besar pergeseran yang digunakan dalam penelitian ini adalah 10%.
- Horizontal Flip* merupakan proses transformasi data citra dengan membalik ke arah horizontal data citra secara acak. preprocessing merupakan tahap pengolahan.

Arsitektur convolutional neural network

Pembuatan arsitektur CNN dimulai dari penentuan ukuran spasial *feature*, jumlah dan jenis *layer*, susunan *layer*, dan *hyperparameter* tiap *layer*. Model arsitektur yang dibuat terbagi menjadi dua bagian yaitu *feature extraction* dan *classification*. Pada bagian *feature ekstraction* terlihat pada Gambar 6. memiliki blok konvolusi dengan jumlah 5 blok dengan jumlah *channel/kernel convolution layer* tiap blok 16, 32, 64, 128, dan 128. Pada bagian *classification* pada Gambar 7. menggunakan 3 *Fully Connected Layer* dengan jumlah *neuron* 512, 512, dan 1 dengan *output activation* menggunakan aktivasi *Sigmoid*.



Gambar 6. Model arsitektur feature extraction.



Classification

Gambar 7. Model arsitektur classification.

Lebih jelasnya model CNN beserta perhitungan parameter dirangkum pada Tabel 1.

Tabel 1. Layer Convolution Neural Network

Layer	Type	Channel	Filter	Stride	Padding	Output	Params
Input	Data layer	1	-	-	-	200x200	-
Convolution Layer	Convolution ReLU	16	3x3	1	1	200x200	160
Pooling layer	Max_pooling	16	2x2	2	1	100x100	-
Convolution Layer	Convolution ReLU	32	3x3	1	1	100x100	4.640
Pooling layer	Max_pooling	32	2x2	2	1	50x50	-
Convolution Layer	Convolution ReLU	64	3x3	1	1	50x50	18.496
Pooling layer	Max_pooling	64	2x2	2	1	25x25	-
Convolution Layer	Convolution ReLU	128	3x3	1	1	25x25	73.856
Pooling layer	Max_pooling	128	2x2	2	1	13x13	-
Convolution Layer	Convolution ReLU	128	3x3	1	1	13x13	147.584
Pooling layer	Max_pooling	128	2x2	2	1	7x7	-
Flatten	Dropout	-	0,2	-	-	12544	-
Fully Connected layer	Dense ReLU Dropout	512	0,2	-	-	512	32.117.76
Fully Connected layer	Dense ReLU Dropout	512	0,2	-	-	1	262.656
Fully Connected layer	Dense Sigmoid	1	-	-	-	1	513
Jumlah Parameter							3.719.681
Parameter dilatih							3.719.681
Parameter tidak dilatih							-

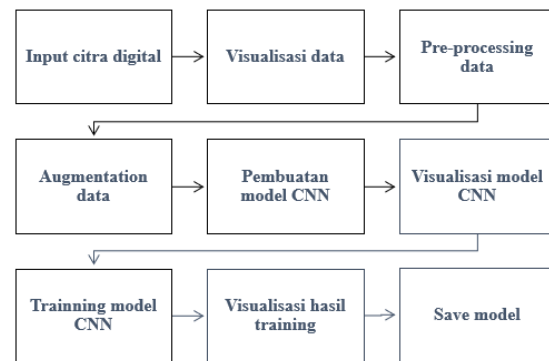
HASIL DAN PEMBAHASAN

Hasil dan pembahasan membahas hasil dari perancangan sistem klasifikasi pneumonia yang meliputi pembahasan tentang bagaimana cara sistem bekerja dan hasil pengujian model

CNN serta analisis dari model CNN yang telah dibangun.

Perancangan Sistem

Dalam perancangan sistem ini, terdapat beberapa tahapan yang dijalankan mulai dari penginputan data citra digital, visualisasi data, *preprocessing* data, *augmentation data*, pembuatan model CNN, visualisasi model cnn, *training* model CNN, visualisasi hasil *training*, *save model*, *load model*, dan testing model. Adapun skema urutan tahapan yang dijalankan pada Gambar 8. sebagai berikut:



Gambar 8. Skema tahapan pada sistem.

Training model CNN

1. Penentuan Parameter

Pada tahap *training* model CNN ini, dataset train yang terdiri dari 3.624 citra kasus pneumonia dan 2.240 citra untuk kasus normal digunakan untuk melatih model CNN. Untuk melatih model CNN tersebut digunakan *loss function* berupa *Binary Crossentropy* dan *optimizer* yaitu *Adam Optimizer*. Parameter lainnya yang sudah ditentukan untuk proses training dapat dilihat pada Tabel 2. sebagai berikut:

Tabel 2. Hyperparameter training

<i>Learning Rate</i>	0,001
<i>Batch Size</i>	32
<i>Max Epoch</i>	50
<i>Patience</i>	2

2. Ekstrak ciri pada proses convolution

Pada model terdapat lima blok konvolusi dimana tiap blok memiliki proses yang sama mulai dari *convolution*, *activation feature*, dan *pooling feature map*. Setiap *channel* yang digunakan pada saat konvolusi suatu inputan memiliki bobot yang berbeda-beda dan menangkap *feature* inputan yang berbeda juga. Selanjutnya, untuk proses *convolutional* pada tiap blok memiliki proses yang sama dengan persamaan (10) fungsi secara umum berdasarkan input, hyperparameter, parameter, dan fungsi aktivasi yang telah ditentukan pada tiap blok sebagai berikut:

$$y_{i^{l+1}, j^{l+1}, d} = \sum_{i=0}^H \sum_{j=0}^W \sum_{d=0}^{D^l} f_{i,j,d^l} \times x_{i^{l+1}, j^{l+1}, d}^l + b_d \dots \dots \dots (10)$$

Dengan $0 \leq i < H$, $0 \leq j < W$, dan $0 \leq d < D = D^{l+1}$. Kemudian hasil dari persamaan (10) dimasukkan kedalam fungsi ReLU dengan persamaan (11) berikut:

$$Y_{i,j,d} = \max\{0; y_{i^{l+1}, j^{l+1}, d}\} \dots \dots \dots (11)$$

Dengan $0 \leq i^{l+1} \leq H^l + 1 = H^{l+1}$, $0 \leq j^{l+1} \leq W^l + 1 = W^{l+1}$, $0 \leq d < D = D^{l+1}$ maka hasil *feature map* dari *convolution layer* adalah $Y_{H^{l+1}, W^{l+1}, D^{l+1}}$ dimana H^{l+1} untuk tinggi *featur map*, W^{l+1} untuk lebar *featur map*, dan D^{l+1} untuk dimensi atau jumlah *channel* dari *featur map*.

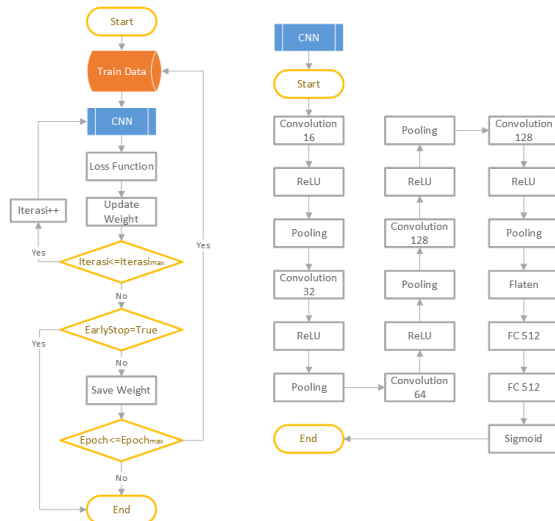
Hasil dari proses konvolusi yang digunakan tiap blok berupa bobot *feature map* yang dapat dilihat pada Tabel 3.

Tabel 3. Hyperparameter training

Blok	Nama Layer	Channel/kernel	Output
1	Convolution 1	0,1542 0,0027 -0,0216 0,1330 -0,0170 -0,1173 0,1209 0,1539 0,0287	
2	Convolution 2	0,0411 -0,0636 0,1127 0,1115 0,1257 -0,0766 0,1417 0,0818 0,0928	
3	Convolution 3	-0,1252 -0,0692 3,26E-05 -0,0294 -0,0449 -0,0172 -0,0174 -0,0487 -0,0043	
4	Convolution 4	0,0434 0,1226 0,0918 0,0185 0,0555 0,0627 0,0774 0,0544 0,0635	
5	Convolution 5	-0,0033 0,0642 0,0739 -0,0355 -0,0484 -0,0326 0,0568 -0,0265 0,0071	

3. Proses training

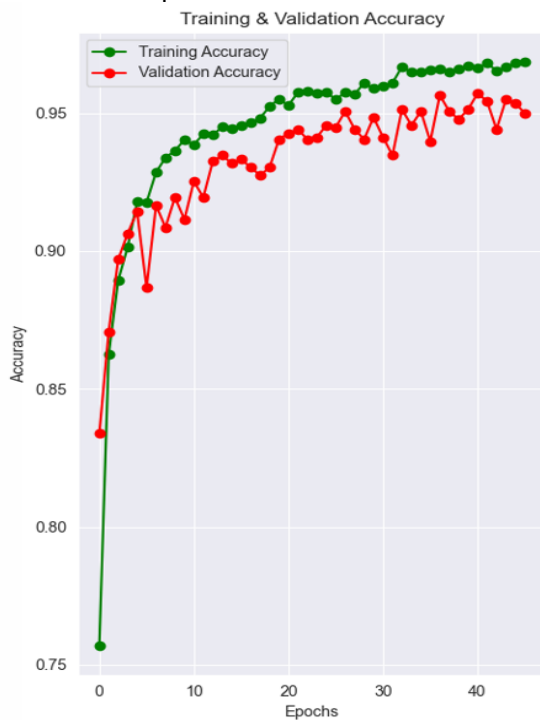
Pada training model terjadi forward propagation dan backpropagation dengan skema training model yang dapat dilihat pada Gambar 9.



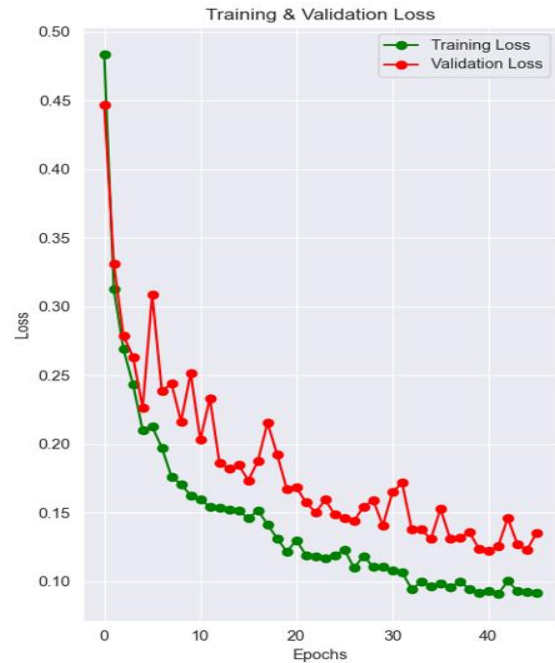
Gambar 9. Diagram alir proses training.

4. Hasil training

Hasil *training* model CNN disajikan dalam bentuk grafik untuk nilai akurasi Gambar 10. dan nilai loss pada Gambar 11. berikut:



Gambar 10. Grafik perbandingan nilai akurasi training dengan validating.



Gambar 11. Grafik perbandingan nilai loss training dengan validating.

Pada tahap training, batas epoch maksimum adalah 50 epoch sedangkan model berhenti melakukan training pada epoch 46 dan menyimpan weight terbaik pada epoch 41 dengan lr $1,5625e-5$. Hasil training didapatkan nilai akurasi proses training sebesar 96,64% untuk training dan 95,72% untuk validating. Sedangkan hasil dari proses training untuk nilai loss yang didapatkan sebesar 0,0929 untuk training dan 0,1220 untuk validating. Dengan nilai akurasi yang diperoleh yang sangat tinggi dan nilai loss yang sangat rendah menandakan model tidak mengalami underfitting yaitu ketidak mampuan model dalam melakukan pembelajaran.

Setelah proses training selesai, model yang disimpan di uji lagi dengan data validation untuk mengetahui apakah model memiliki kinerja yang baik dan optimal. Hasil pengujian dapat dilihat pada Tabel 4.

Tabel 4. Hyperparameter training

		Kategori Sebenarnya	
		Normal	Pneumonia
Prediksi	Normal	588	34
	Pneumonia	30	726
Jumlah		612	760

Dari Tabel 4. dapat dicari nilai precision, recall, f1-score, dan Accuracy akan disajikan dalam Tabel 5. sebagai berikut:

Tabel 5. Hasil perhitungan nilai Precision, Recall, F1-score, MCC dan Accuracy

Kategori	Hasil nilai				
	Precision (%)	Recall (%)	F1-score (%)	MCC	Accuracy (%)
Normal	95,15	94,53	94,84	0,91	95,36
Pneumonia	95,53	96,03	95,78		

Hasil pengujian menggunakan data validation sebanyak 1.378 citra didapatkan nilai MCC sebesar 0,91 menandakan korelasi hubungan antara kedua kategori terhubung positif, hal ini ditunjukkan dari nilai MCC positif dan mendekati angka 1. Nilai MCC ini untuk mengevaluasi bagaimana kinerja model dalam membedakan antara kategori normal atau pneumonia.

Nilai Accuracy model yang diperoleh pada pengujian model sebesar 95,36%, nilai ini untuk mengevaluasi sebagaimana kedekatan hasil prediksi dengan hasil yang sebenarnya. Semua nilai yang diperoleh dari hasil pengujian berada diatas 90% yang menandakan kinerja dari model dalam klasifikasi citra pneumonia atau normal sangat baik. Selisih nilai akurasi yang diperoleh dari training validation dengan pengujian model menggunakan data validation sebesar 0,36%. Selisih nilai akurasi yang sangat kecil menandakan model yang dibuat bekerja dengan optimal tanpa terjadi overfitting.

KESIMPULAN DAN SARAN

Berdasarkan hasil training model CNN yang sudah dibuat, maka dapat disimpulkan sebagai berikut:

1. Model CNN terbaik yang didapatkan ketika proses training pada epoch 41 dengan dengan perolehan nilai training accuracy 96,64% dan training loss sebesar 0,0929. Dengan perolehan nilai akurasi yang tinggi dan nilai loss yang rendah maka model CNN tersebut dapat dinyatakan sangat mampu untuk mengklasifikasi pneumonia pada citra X-rays paru-paru.
2. Hasil tahap pengujian mendapatkan nilai Precision 95,15%, Recall 94,53%, dan F1-score 94,84% untuk kelas normal.

Sedangkan untuk kelas pneumonia memperoleh nilai Precision 95,53%, Recall 96,03%, dan F1-score 95,78%. Nilai MCC sebesar 0,91 dan nilai Accuracy model sebesar 95,36%, menunjukkan model CNN dapat diimplementasikan dan hasil klasifikasi dapat dijadikan tinjauan para dokter dalam mendianogsa pasien sebagai bagian dari tindakan pemeriksaan untuk memastikan pasien pengidap pneumonia.

Untuk pengembangan lebih lanjut sebaiknya sistem *training* dan testing dibuat dalam bentuk User Interface (UI) software atau aplikasi sehingga memudahkan pengguna dalam pengoperasiannya. Dataset yang digunakan untuk selanjutnya lebih diperbanyak dan seimbang antara tiap kategori kelas. Sebelum *training* model dilakukan, sebaiknya diterapkan segmentasi data agar ekstraksi ciri yang dilakukan oleh model CNN lebih difokuskan pada bagian paru-paru saja.

DAFTAR PUSTAKA

- Abbas, A. dkk. 2020. "Classification of COVID-19 in Chest X-ray Images Using DeTraC Deep Convolutional Neural Network". Applied Intelligence volume 51:854–864.
- Ahmad, Abu. 2017. "Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning". Jurnal Teknologi Indonesia.
- Aji, L. A., Pratiwii, H., dan Sulistijowati, Sri H. 2019. "Klasifikasi Pneumonia Menggunakan Metode Convolutional Neural Network dengan Optimasi Adaptive Momentum". Indonesian Journal of Statistics and Its Applications Vol. 3 No. 3 (2019), page 331 - 340 (eISSN:2599-0802).
- Arrofiqoh, E. dan Harintaka. "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi". Geomatika Volume 24 No.2 November 2018: 61-68
- Bahri, R. S. dan Maliki, I. 2012. "Perbandingan Algoritma Template Matching dan Feature Extraction pada Optical Character Recognition". Jurnal Komputer dan Informatika (KOMPUTA) Edisi 1 Vol. 1, pp. 29-35.

- Christanto, W. S. 2018. "Klasifikasi Pneumonia Menggunakan Convolutional Neural Network", Tesis tidak diterbitkan. Universitas Sumatra Utara.
- Danukusumo, K. P. 2017. "Implementasi Deep Learning Menggunakan Convolutional Neural Network untuk Klasifikasi Citra Candi Berbasis GPU", Tesis tidak diterbitkan. Program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Atma Jaya Yogyakarta.
- Gifari, J. 2020. "Belajar Data Science". Vol. 11 Series 61. Diakses dari <https://www.dqlab.id/belajar-data-science-pahami-tensflow>.
- Hakim, D. M. dan Rainarli, E. 2019. "Optical Music Recognition Pada Citra Notasi Musik Menggunakan Convolutional Neural Network". TechnoCOM Vol. 8 No. 3 pp: 214-226.
- Hokya. 2017. "Buku Panduan Pemrograman Python". Pusat Pemberdayaan Informatika dan Desa.
- Kermany, D., Zhang, K., dan Goldbaum, M. 2018. "Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification". Diakses dari <https://www.kaggle.com/paultimothymoon/ey/chest-xray-pneumonia>
- Maysanjaya, I Md. D. 2020. "Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network". Jurnal Nasional Teknik Elektro dan Teknologi Informasi Vol. 9 No. 2 ISSN 2301 – 4156.
- Nugroho, B. dan Yulia E. P. 2021. "Kinerja Metode CNN Untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input". Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK) Vol. 8, No. 3, hlm. 533-538. p-ISSN: 2355-7699, e-ISSN: 2528-6579.
- Pane, Marry D. C. 2020. "Pneumonia". Diakses pada tanggal 12 Januari 2020 dari <https://www.alodokter.com/pneumonia/>.
- Putra, Sindunuraga R. 2015. "Implementasi Convolutional Neural Network Untuk Klasifikasi Obyek Pada Citra". Diakses dari https://repository.its.ac.id/71292/1/51111_00076-Undergraduate%20Thesis.
- Sanjaya, J. dan Ayub, M. 2020. "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup". Jurnal Teknik Informatika dan Sistem Informasi Vol. 6 No. 2 p-ISSN : 2443-2210 e-ISSN : 2443-2229.
- Saputra, I. dan Ajeng. 2022, Dinar K. "Mechine Learning Untuk Pemula". Bandung: INFORMATIKA.
- Shapiro, L. G. dan Stockman, G.. 2001. "Computer Vision". 1st edition, Prentice Hall.
- Shidarta, H. A.. 2018. "Introduction to Open CV". Diakses pada tanggal 16 Juni 2020 dari <https://binus.ac.id/malang/2017/10/introduction-to-open-cv/>
- Stephen, O., Sain, M., Joshep, U. M., dan Jeong, D. 2019. "An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare". Journal of Healthcare Engineering Volume 2019, Article ID 4180949.
- Suartika, I. W., dkk. 2016. "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101". Jurnal Teknik ITS Vol. 5. No. 1 ISSN: 2337-3539 (2301-9271 Print).
- Sudoyo. 2005. "Buku Ajar Ilmu Penyakit Dalam". Jilid III Edisi IV. Penerbit FK UI.
- Suyanto, Ramadhani, K. N., dan Mandala, S. 2019. "Deep Learning Modernisasi Mechine Learning untuk Big Data". Bandung: INFORMATIKA.
- United Nations Children's Fund (UNICEF). 2019. "Lembaga kesehatan dan anak memperingatkan satu anak meninggal akibat pneumonia setiap 39 detik". Diakses dari <https://www.unicef.org/indonesia/id/press-releases/lembaga-kesehatan-dan-anak-memperingatkan-satu-anak-meninggal-akibat-pneumonia-setiap>.
- Widodo, R., Badriyah, T. dan Syarif, I. 2020. "Detection Of Lung Cancer Cell Based On Cytological Examination Using Convolutional Neural Network". Kumpulan Jurnal Ilmu Komputer vol. 07 No. 3, ISSN: 2406-7857.
- World Health Organization (WHO), 2019. "Pneumonia". Diakses dari <https://www.who.int/news-room/factsheets/detail/pneumonia>