

# KLASIFIKASI CITRA PNEUMONIA MENGGUNAKAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *PNEUMONIA IMAGE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK (CNN) ARCHITECTURE*

Aan Rachmatullah Pratama<sup>1)</sup>, Adi Fajaryanto Cobantoro<sup>2)</sup>

<sup>1,2)</sup> Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Ponorogo  
Jl. Budi Utomo No.10, Ronowijayan, Kec. Ponorogo, Kabupaten Ponorogo, Jawa Timur 63471  
Email : [seal\\_jme@hotmail.com](mailto:seal_jme@hotmail.com)<sup>1)</sup>

## Abstrak

*Pneumonia adalah infeksi atau peradangan akut pada bagian jaringan paru yang disebabkan oleh berbagai mikroorganisme seperti bakteri, virus, parasit, jamur, kerusakan fisik paru ataupun bahan kimia. Pneumonia dapat menyerang orang dewasa maupun anak-anak, banyak kasus yang terjadi, terutama pada Negara berkembang dimana kebanyakan mengandalkan energi yang berpotensi menyebabkan polusi udara yang akan berdampak pada pernafasan manusia. Klasifikasi citra Pneumonia dari hasil rontgen dengan algoritma Convolutional Neural Network yang memiliki metode alur pemecahan masalah yang menyerupai pola pikir manusia. Pada program ini melakukan penelitian tentang membandingkan performa dari kedua model arsitektur Convolutional Neural Network arsitektur AlexNet dengan GoogLeNet. Pada hasil confusion matrix mendapatkan hasil tingkat akurasi 0,79 untuk arsitektur Alexnet dan untuk arsitektur GoogLeNet mendapatkan hasil akurasi 0,78. Umumnya akurasi dari GoogLeNet lebih tinggi namun pada penelitian ini AlexNet mendapatkan akurasi yang lebih tinggi, namun GoogLeNet memiliki loss yang lebih rendah, loss dan Accuracy dipengaruhi callback yang didalamnya terdapat epoch. Pada hasil implementasi kedua model dari web app menggunakan flask dan Google colab, dari jumlah masukan 16 citra 15 prediksi dilakukan benar dan 1 salah mendapatkan hasil akurasi 0,94.*

**Kata kunci :** AlexNet, CNN, GoogLeNet, Pneumonia.

## ABSTRACT

*Pneumonia is an infection or acute inflammation of the lung tissue caused by various microorganisms such as bacteria, viruses, parasites, fungi, physical damage to the lungs or chemicals. Pneumonia can attack adults and children, many cases occur, especially in developing countries where most rely on energy which has the potential to cause air pollution which will have an impact on human respiration. Pneumonia image classification from X-ray results with the Convolutional Neural Network algorithm which has a problem-solving flow method that resembles the human mindset. This program conducts research on comparing the performance of the two models of the Convolutional Neural Network architecture, AlexNet and GoogLeNet architectures. The results of the confusion matrix get an accuracy rate of 0.79 for the Alexnet architecture and for the GoogLeNet architecture it gets 0.78 accuracy results. Generally the accuracy of GoogLeNet is higher but in this study AlexNet got a higher accuracy, but GoogLeNet has a lower loss, loss and Accuracy are affected by callbacks which contain epochs. In the results of the implementation of the two models from the web app using flask and Google colab, from the number of inputs 16 images, 15 predictions were made correctly and 1 incorrectly got 0.94 accuracy results.*

**Kata kunci :** AlexNet, CNN, GoogLeNet, Pneumonia.

## 1. PENDAHULUAN

Pneumonia merupakan peradangan akut yang terjadi pada bagian jaringan paru-paru, penyebab terjadinya adalah kerusakan fisik pada paru dan mikroorganisme seperti virus, bakteri, parasit, bahan kimia, dan jamur. Pneumonia dapat menyerang siapa saja, termasuk anak-anak, remaja, dewasa muda, dan yang paling berbahaya yakni orang tua [1], Orang tua yang memiliki penyakit penyerta berada pada peningkatan resiko buruk kondisi sistem kekebalan tubuh. Berdasarkan Riset Kesehatan Dasar 2018 (RISKESDAS), prevalensi pneumonia meningkat dari sekitar 1,8% pada tahun 2013 menjadi sekitar 2%. Menurut data Kementerian Kesehatan tahun 2014, jumlah penderita pneumonia di Indonesia pada tahun 2013 adalah seperempat dari jumlah penduduk, dan jumlah orang yang meninggal akibat pneumonia sebesar 1,19% [2].

Stephen Okeke menyatakan, Resiko yang muncul pada penyakit Pneumonia yang sangat berbahaya bagi banyak orang dewasa maupun anak-anak di dunia, terutama terjadi pada negara berkembang dimana kebanyakan orang menghadapi kemiskinan, negara yang berkembang memiliki banya pabrik – pabrik yang banyak menggunakan energi yang akan menyebabkan polusi udara serta berdampak pada sistem pernafasan manusia dan makhluk hidup yang disekitarnya [3].

Dalam akhir-akhir ini *machine learning* menjadi sebuah trend, sebagai bidang *artificial Intelegnce* berkembang sangat pesat dan terus dikembangkan oleh para ilmuwan di seluruh dunia. Ini adalah inti dari berbagai produk teknologi tinggi pada masa sekarang. Perannya sangat krusial dalam pengembangan industri 4.0 yang sarat dengan transformasi digital. *Machine Learning* adalah cabang dari kecerdasan buatan, *Machine learning* memiliki arti yang lebih spesifik, yaitu penggunaan metode statistik untuk memungkinkan komputer mempelajari pola dalam data yang sedang diolah [4].

Citra hasil rontgen yang telah diagnostik oleh dokter atau pakar dapat diproses menggunakan teknik Deep Learning dengan Convolutional Neural Network (CNN). Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi citra Pneumonia secara otomatis dengan menggunakan model sederhana yang menggabungkan metode CNN serta arsitektur dari AlexNet dan GoogLeNet. Pendekatan ini memanfaatkan satu set neuron untuk mengekstrak fitur yang relevan dari citra, memperkuat kemampuan klasifikasi untuk mendapatkan hasil yang lebih optimal.

Klasifikasi adalah suatu model dari analisis data yang mengekstraksi model yang berupa gambar, angka, dan suara untuk menggambarkan mengategorikan atau kelas dari data. Dalam klasifikasi, pengklasifikasian atau model yang dibangun untuk memprediksi label kelas (kategorial), misalnya sebuah cuaca hujan atau terik. Kategori ini dapat diwakilkan oleh nilai diskrit, pengurutan antar nilai tidak mempunyai arti. Klasifikasi sendiri terdiri atas dua langkah atau dua proses, proses yang pertama adalah proses pembelajaran (proses pengklasifikasian dibangun), sedangkan proses kedua adalah proses klasifikasi [5].

## 2. DASAR TEORI

*Convolutional Neural Network* (CNN) merupakan sebuah algoritma turunan dari *deep learning*. CNN mencakup banyak lapisan representasi. Karena struktur yang dalam ini, CNN dapat secara otomatis mendapatkan karakteristik representasi dari data melalui transformasi nonlinier dan diperkirakan oleh fungsi nonlinier. Struktur CNN terdiri atas ekstraksi fitur yang terdiri atas convolutional layer yang biasanya diikuti oleh *pooling layer* dan pengklasifikasi *softmax*. Pada lapisan konvolusional mengekstraksi fitur dari citra, sedangkan pada *pooling layer* mengurangi dimensi dan mengurangi waktu komputasi. Arsitektur ini dapat mencapai bentuk regularisasi dengan sendirinya. Fitur yang diekstraksi kemudian dimasukkan ke dalam lapisan *softmax* atas untuk proses klasifikasi [6].

Tipe lapisan pada Convolutinal Neural Network terbagi dalam dua bagian. Pada bagian pertama adalah feature extraction layer, terletak di bagian depan dari arsitektur yang memiliki banyak sekali lapisan yang tersusun, Setiap lapisan terdiri dari neuron yang terintegrasi dengan bagian awal dari layer yang sebelumnya. Convolutional layer adalah Lapisan jenis pertama dan pooling layer adalah lapisan kedua. Setiap lapisan Convolutional layer memiliki fungsi mobilisasi dengan posisi yang berselang-seling antara kedua jenis layer tersebut.


Lapisan ini memaksukan inputan berupa citra secara langsung sehingga dapat memproses sampai menghasilkan output berupa citra, yang dipergunakan untuk diolah pada lapisan berikutnya. Lapisan kedua adalah *classification layer*, tersusun atas beberapa lapisan yang setiap lapisan tersusun atas sel-sel saraf yang terhubung secara *fully connected* dengan lapisan-lapisan lainnya. *Layer* ini menerima input dari hasil keluaran lapisan ekstrasi fitur citra berupa vektor, kemudian ditransformasikan seperti *Multi Neural Networks* dengan tambahan beberapa *hidden layer* karena pada *hidden layer* tidak dapat terdeteksi pada *Convolutinal Layer* [7]. Convolutional Neural Network (CNN), terdapat dua arsitektur utama yang memainkan peran penting, yaitu AlexNet dan GoogLeNet. AlexNet, sebagai terobosan yang memengaruhi perkembangan

signifikan pada periode tertentu, menggabungkan teknik-teknik inovatif seperti ConvNet, ReLU, dan augmentasi data.

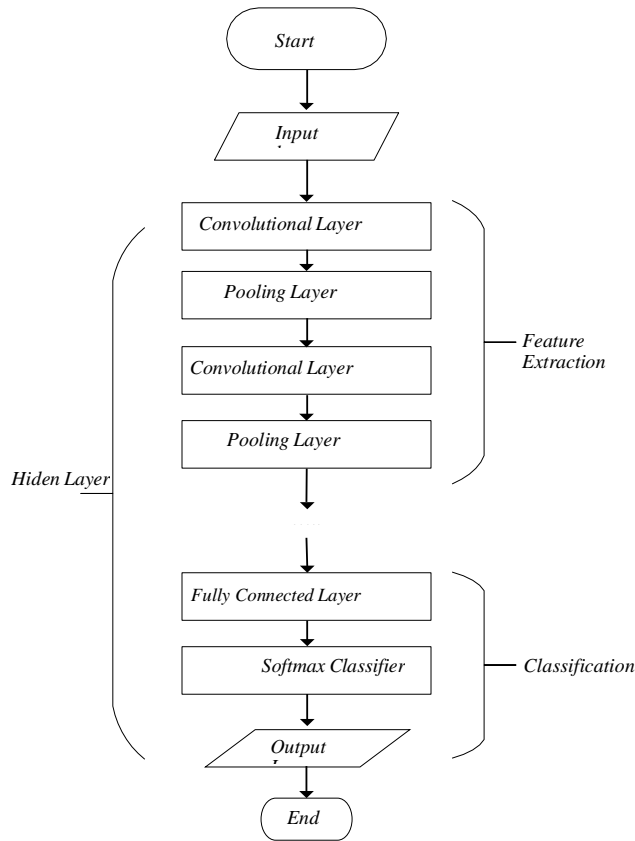
AlexNet merupakan terobosan yang signifikan pada masa itu, menggabungkan ConvNet dengan teknik skip regularization, memanfaatkan ReLU sebagai aktivasi, dan menerapkan fungsi augmentasi data. Dirancang untuk melakukan klasifikasi pada 1000 kategori, AlexNet terdiri dari 5 lapisan Convolutional, 3 lapisan pooling, 2 lapisan DropOut, dan 3 lapisan fully connected [8]. Arsitektur AlexNet dipakai guna mencapai ekstraksi fitur melalui proses pelatihan pada kumpulan data yang awalnya dipilah ke dalam dataset pelatihan, pengujian, dan validasi [9]. Sedangkan GoogLeNet, yang dikenal sebagai Inception V1, ditandai dengan penggunaan jaringan yang lebih dalam dan kompleks, serta ukuran yang lebih besar yang berpotensi meningkatkan tingkat akurasi. Sebagai model dan arsitektur yang dimodifikasi dari Convolutional Neural Network (CNN), GoogLeNet mampu mengurangi kesalahan sebesar 6,67%, melampaui kinerja AlexNet sebesar 15,3% [10].

### 3. METODOLOGI PENELITIAN

“Data dalam penelitian ini menggunakan dataset Pneumonia yang digunakan pada penelitian “Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning”, yang didalam penelitian tersebut berisi orang-orang yang berpengalaman dalam bidang Artificial Integence maupun dalam bidang klasifikasi Citra medis” [11]. Pemilihan dataset bertujuan untuk penelitian yang akan membandingkan arsitektur CNN AlexNet dan GoogLeNet. *Datasets* pertama Pneumonia terdiri dari 3875 citra dan datasets Normal terdiri dari 1340 citra, beberapa sample Citra dapat ditunjukkan pada Gambar 1, berikut :

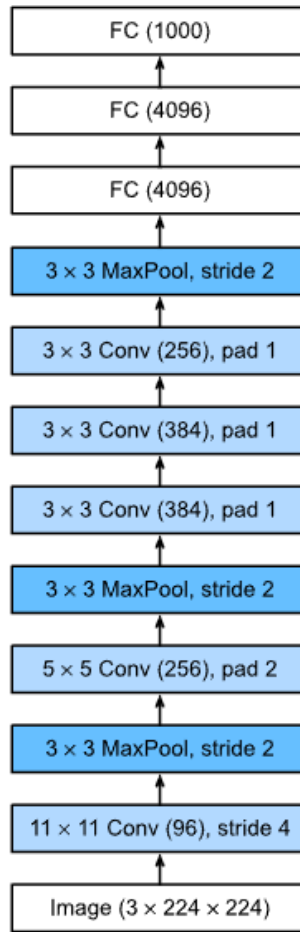


**Gambar 1.** Citra Pneumonia



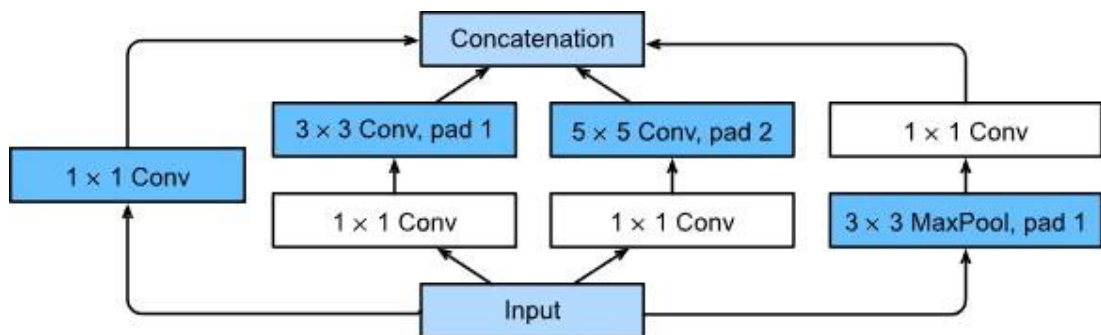
**Gambar 2.** Flowchart Pemodelan CNN

Gambar 2. adalah *flowchart* pemodelan CNN, pada proses pertama data dimasukkan dalam bentuk citra, dan data diambil dari setiap piksel citra dengan “panjang x lebar x 1” (untuk citra hitam putih (*grayscale*) dan “panjang x Lebar x 3” untuk gambar berwarna (RGB). Langkah selanjutnya adalah citra diolah sedemikian rupa untuk dilanjutkan proses *encoding* citra ke *features* dalam bentuk angka yang mewakili citra. *Features extraction* terdiri dari dua bagian utama, *convolutional layer* dan *pooling layer*. Untuk *Features Extraction*, dapat di sesuaikan jumlah *convolutional layer* dan *pooling layer* sesuai kebutuhan. Semakin tinggi hasil, semakin dalam arsitekturnya dan meningkat akurasi klasifikasinya [4].



**Gambar 3.** Arsitektur AlexNet


Arsitektur AlexNet pada gambar 3, terdiri dari delapan lapisan: lima *convolution layer*, 2 lapisan *fully-connected hidden layer*, dan satu *fully-connected Output Layer*. Pada lapisan pertama AlexNet, berbentuk *layer convolutional* adalah 11 x 11. Karakteristik dari citra ImageNet yang umumnya memiliki ukuran citra yang besar, hal ini menyebabkan objek-objek dalam data ImageNet cenderung memakan lebih banyak piksel dalam citra tersebut. Oleh karena itu, diperlukan *convolution layer* yang lebih besar untuk menangkap objek. Bentuk tabel *convolutional layer* kedua menjadi 5x5, diikuti oleh 3x3. Selain itu, setelah lapisan konvolusi pertama, kedua dan kelima, jaringan menambahkan *max pooling layer* dan melangkah ke *layer* terakhir 3 x 3, dan pada bagian akhir melakukan gabungan pada setiap lapisan untuk melakukan proses konvolusi [12].



**Gambar 4.** Inception Block GoogLeNet

Seperti yang ditunjukkan pada Gambar 4, blok startup terdiri dari empat jalur paralel. Tiga jalur pertama menggunakan lapisan konvolusi dengan ukuran jendela 1 x 1, 3 x 3 dan 5 x 5 untuk mengekstrak informasi tentang dimensi spasial yang berbeda. Dua jalur tengah melakukan

konvolusi pada input untuk mengurangi jumlah saluran, sehingga mengurangi kompleksitas model. Jalur keempat menggunakan lapisan komposit maksimum, diikuti oleh lapisan komposit untuk memvariasikan jumlah saluran. Keempat jalur menggunakan *padding* yang tepat untuk memiliki tinggi dan lebar yang digunakan untuk *input* dan *output*. *Output* di sepanjang setiap baris digabungkan di sepanjang dimensi dan termasuk *output* blok. *Hyperparameter* yang didefinisikan dari blok *startup* adalah jumlah *output layer* [13].



**Gambar 5.** Arsitektur GoogLeNet

Arsitektur GoogleNet pada Gambar 5, pertama menggunakan lapisan konvolusi 64-channel 7 x 7. Yang kedua menggunakan dua lapisan konvolusi: 64-channel 1x 1 convolutional layer, dan 3 x 3 convolutional layer, sesuai jalur kedua di inception block. Modul ketiga menghubungkan dua inception block secara seri. Jumlah luaran dari inception block pertama dan rasio antara empat baris. Baris kedua dan ketiga mengurangi baris input, terhubung ke convolutional layer kedua. Jumlah luaran dari inception block kedua meningkat, dan rasio luaran antara baris keempat dan kedua dan ketiga mengurangi jumlah dari blok. Modul kelima memiliki dua Inception block dan output layer. Layer untuk setiap jalur sama di modul ketiga dan keempat, tetapi berbeda dalam nilai spesifiknya. Blok ini menggunakan lapisan penyatuan rata-rata global untuk mengubah tinggi dan lebar setiap saluran menjadi 1. Mengubah output menjadi array dua dimensi diikuti lapisan yang terhubung penuh dengan jumlah outputnya adalah jumlah kelas label [13].

*Confusion matrix* dapat menggambarkan nilai dari arsitektur pada setiap kelas yang berbeda dan tidak tergantung pada algoritma klasifikasi. Tujuan dari *confusion matrix* ada pada penelitian ini digunakan untuk mengukur akurasi padaperforma dari arsitektur. *Confusion matrix* dapat mengevaluasi hasil dari nilai akurasi, presisi dan *recall*. Nilai akurasi adalah persentase ketepatan *record* data yang di klasifikasi secara benar setelah serta melakukan pengujian pada hasil klasifikasi. *Percission* merupakan hasil pengujian yang diprediksi positif benar pada pengujian data yang sebenarnya. Sedangkan *Recall* adalah proporsi kasus positif yang sebenarnya yang diprediksi positif secara benar [14].



		Predicted Class	
		A	B
True Class	A	TP	FN
	B	FP	TN

Gambar 6. Binnary Confusion Matrix

Gambar 6, adalah tabel kebenaran dari *binary confusion matrix*. Selain itu, evaluasi yang diberikan dengan perbandingan dari dua yang disajikan. Metrik evaluasi untuk mengevaluasi kinerja arsitektur terdiri dari empat faktor yaitu, *True Positive (TP)*, *False Negative (FN)*, *False Positive (FP)*, dan *True Negative (TN)*, untuk mendapatkan hasil N (*negative*) dan juga P (*positive*) [15], ditunjukkan pada Tabel 1.

Tabel 1. Tabel kebenaran *positive* dan *negative*

True Class → False Class ↓	True Positive	True Negative
Predict Positive	TP	FP
Predict Negative	FN	TN
	P = TP + FN	N = FP + TN

Untuk mendapatkan hasil *accuracy*, *percission & recall*, dan *F-score* diperlukan persamaan (1), (2), (3), (4) sebagai berikut ini :

$$accuracy = \frac{TP+TN}{P+N} \dots\dots\dots (1)$$

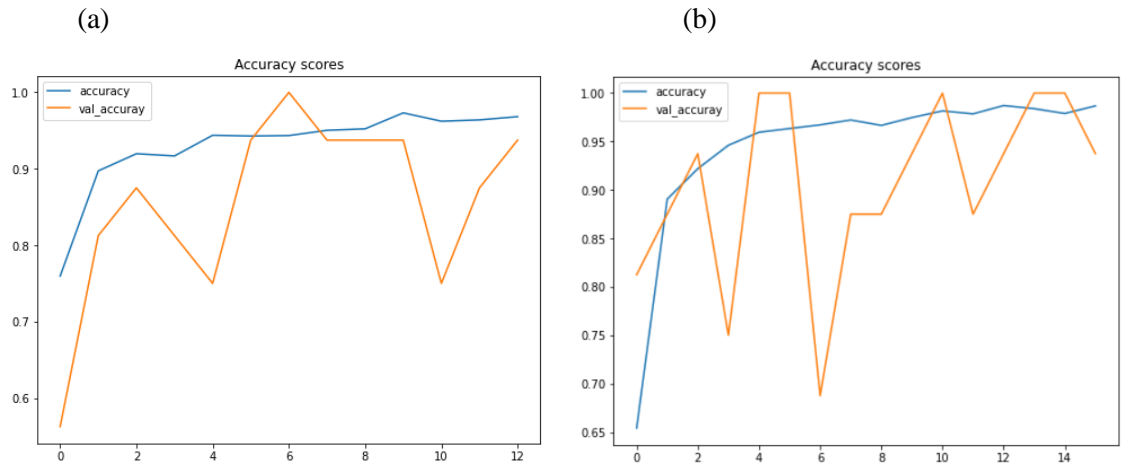
$$Percision = \frac{TP}{TP+FP} \dots\dots\dots(2)$$

$$Recall = \frac{TP}{P} \dots\dots\dots (3)$$

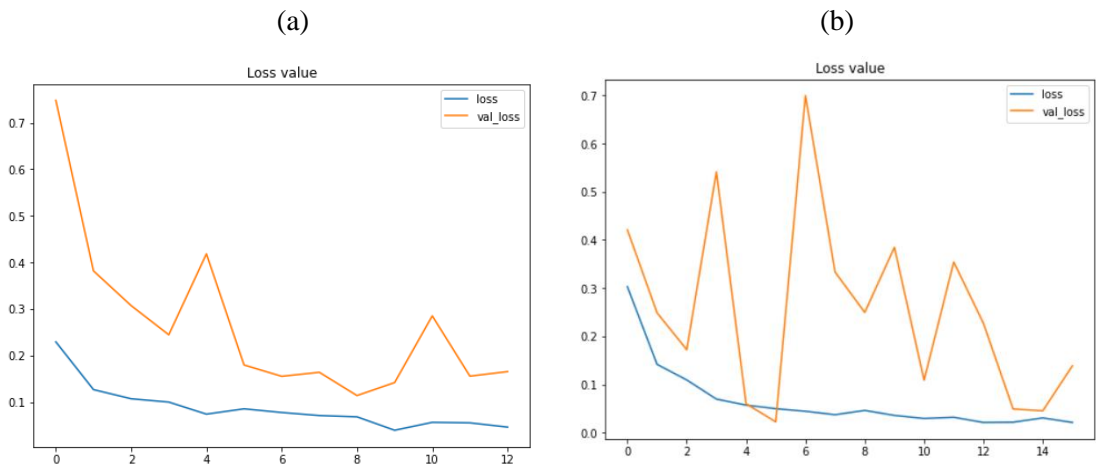
$$F = \frac{2(percission \times recall)}{percission+recall} \dots\dots\dots (4)$$

**4. PENGUJIAN DAN PEMBAHASAN**

Untuk hasil akhir dari kedua model, pada proses pelatihan menggunakan arsitektur alexnet mendapatkan hasil akurasi 0,79 Sedangkan untuk pelatihan menggunakan arsitektur GoogLeNet mendapatkan hasil akurasi 0,78. Sedangkan hasil dari loss kedua model yang pertama menggunakan arsitektur alexnet 0,18 sedangkan googlenet mendapatkan loss 0,13. Untuk hasil training mendapatkan grafik pada Gambar 7. *accuracy* dan Gambar 8. *loss* berikut ini :

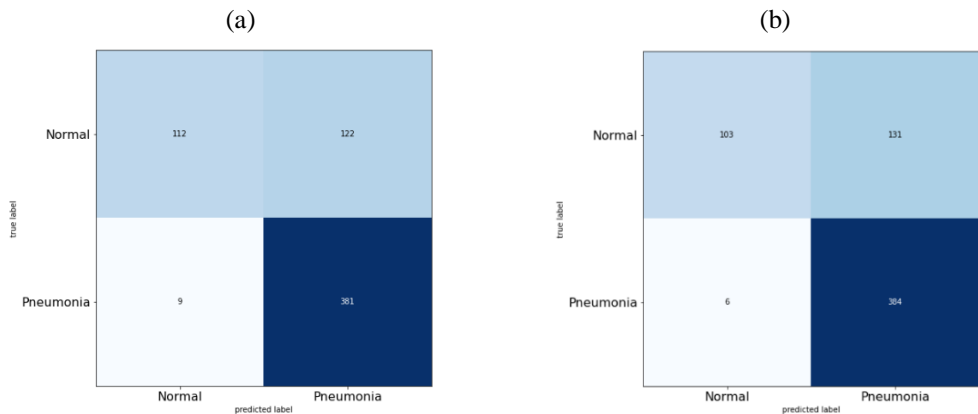


**Gambar 7.** Grafik Akurasi pelatihan (a) AlexNet (b) GoogLeNet



**Gambar 8.** Grafik Loss Pelatihan (a) AlexNet (b) GoogLeNet

Grafik pada arsitektur AlexNet dilihat untuk konsistensi naik turun tidak banyak perubahan yang drastis, namun berbarlik dari konsistensi pada arsitektur GoogLeNet grafik naik dan turun nya sangat drastis yang disebabkan oleh *inception block* yang dimiliki oleh GoogLeNet yang memiliki perputaran lumayan banyak berdampak pada naik dan turunnya grafik *loss* maupun *accuracy*.



**Gambar 9.** Confusion Matrix (a) AlexNet (b) GoogLeNet



Pada Gambar 9.a AlexNet dan Gambar 9.b GoogLeNet Hasil *confusion matrix* menghasilkan skala 2 × 2 terbagi kedalam 2 *class* yang didefinisikan pada tabel menjadi Normal (n) dan Pneumonia (p). Berikut sajian dalam bentuk Tabel 2. dan Tabel 3.:

**Tabel 2.** *Confusion Matrix AlexNet*

<i>True</i> → <i>Predicted</i> ↓	n	p	Total
n	112	122	234
P	9	381	390
<i>Total Predict</i>	318	171	624

**Tabel 3.** *Confusion Matrix GoogLeNet*

<i>True</i> → <i>Predicted</i> ↓	n	p	Total
n	103	131	234
p	6	384	390
<i>Total Predict</i>	318	171	624

Berdasarkan Tabel 2, *confusion matrix* yang menggunakan arsitektur AlexNet dengan skala 2 × 2 nilai TP (*true positive*) normal 112 dan pneumonia 381, FP (*false positive*) normal 9 dan pneumonia (122), FN (*false negative*) normal 122 dan 9 pneumonia, TN (*true negative*) pneumonia 381 dan normal 112. Sedangkan Tabel 3, *confusion matrix* yang menggunakan arsitektur GoogLeNet dengan skala 2 × 2 nilai TP (*true positive*) normal 64 dan pneumonia 390, FP (*false positive*) normal 170 dan pneumonia 0, FN (*false negative*) pneumonia 0 dan normal 170, TN (*true negative*) pneumonia 390 dan normal 64. Untuk perhitungan di tunjukan dibawah ini :

Perhitungan pada *percission AlexNet*.

$$Percission\ n = \frac{TP}{(TP+FP)} = \frac{112}{(112+9)} = 0,93 \quad Percission\ p = \frac{TP}{(TP+FP)} = \frac{381}{(381+122)} = 0,73$$

Perhitungan pada *recall GoogLeNet*.

$$Recall\ n = \frac{TP}{P} = \frac{TP}{(TP+FN)} = \frac{103}{(103+131)} = 0,44 \quad Recall\ p = \frac{TP}{P} = \frac{TP}{(TP+FN)} = \frac{384}{(384+6)} = 0,98$$

Perhitungan pada F-score AlexNet.

$$F1\ n = \frac{2(perc.. \times recall)}{preci..+recall} = \frac{(2(0,93 \times 0,48))}{(0,93+0,48)} = 0,63 \quad F1\ p = \frac{2(perci.. \times recall)}{preci..+recall} = \frac{(2(0,76 \times 0,98))}{(0,76+0,98)} = 0,86$$

Perhitungan pada *accuracy AlexNet*.

$$P = TP + FN = 112 + 122 = 234$$

$$N = FP + TN = 9 + 381 = 390$$

$$Accuracy = \frac{TP+TN}{P+N} = \frac{(112+381)}{(234+390)} = 0,79$$

Perhitungan pada *accuracy GoogLeNet*.

$$P = TP + FN = 103 + 131 = 234$$

$$N = FP + TN = 6 + 384 = 390$$

$$Accuracy = \frac{TP+TN}{P+N} = \frac{(103+384)}{(234+390)} = 0,78$$

Hasil perhitungan manual klasifikasi dari kedua arsitektur Pada tabel 4. dan 5 :

**Tabel 4.** Perhitungan manual klasifikasi AlexNet

<i>report</i>	<i>Percission</i>	<i>Recall</i>	<i>F -score</i>	<i>suport</i>
<i>n</i>	0,93	0,48	0,63	234
<i>p</i>	0,76	0,98	0,85	390
<i>accuracy</i>			0,79	624

**Tabel 5.** Perhitungan manual klasifikasi GoogLeNet

<i>report</i>	<i>Percission</i>	<i>Recall</i>	<i>F -score</i>	<i>suport</i>
n	0,94	0,44	0,60	234
p	0,75	0,98	0,85	390
accuracy			0,78	624

Namun tidak hanya pada hasil klasifikasi menggunakan hitungan manual pada penelitian ini juga menggunakan sistem untuk mendapatkan hasil, jadi pada dasar penelitian ini menggunakan 2 kali validasi dengan hitungan manual dan hasil *uotput classification repot* dari kernel *notebook* pada Gambar 10 dan Gambar 11 berikut ini :

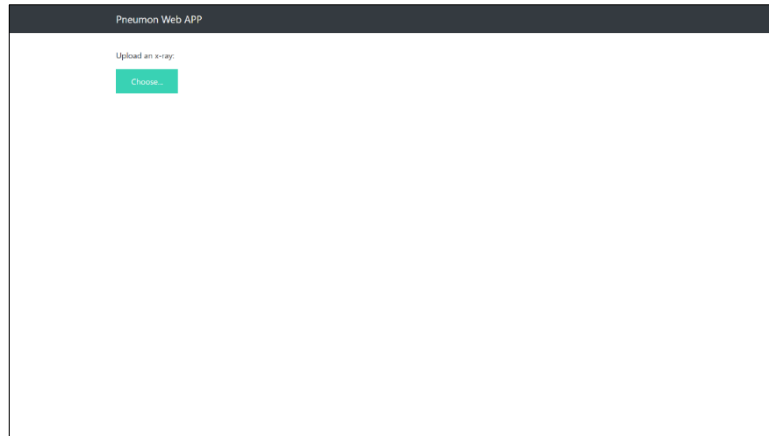
	precision	recall	f1-score	support
0	0.93	0.48	0.63	234
1	0.76	0.98	0.85	390
accuracy			0.79	624
macro avg	0.84	0.73	0.74	624
weighted avg	0.82	0.79	0.77	624

**Gambar 10.** *Classification report Alexnet*

	precision	recall	f1-score	support
0	0.94	0.44	0.60	234
1	0.75	0.98	0.85	390
accuracy			0.78	624
macro avg	0.85	0.71	0.72	624
weighted avg	0.82	0.78	0.76	624

**Gambar 11.** *Report kernel GoogLeNet*

Untuk penelitian ini proses pembuatan aplikasi yang berbasis website menggunakan *framework* Flask. Flask adalah platform yang umum digunakan pada pemrograman web yang berbasis python karena dapat memanggil dan menerapkan library python secara mudah. Dengan berbagai macam keunggulan python yang memiliki sangat banyak library dan dapat diterapkan. Bantuan jinja sebagai user interface dan werkezeug sebagai WSGI (Web Server Gateway Interface) atau lebih mudah di definisikan sebagai server untuk menaruh website tersebut untuk tampilan web dapat dilihat pada Gambar 12.



Gambar 12. Tampilan Web Application

Peneliti menjalankan klasifikasi dengan 2 arsitektur menggunakan web yang sama dan seluruh parameter juga sama, hanya mengganti pada bagian model dari hasil yang sudah disimpan pada pembuatan model. Citra yang digunakan untuk pengujian masih dari *dataset* yang berada pada direktori val.

Tabel 6. Hasil Klasifikasi AlexNet

Prediksi	normal	pneumonia
Benar	7	8
Salah	1	0
Total benar		15

Tabel 7. Hasil Klasifikasi GoogLeNet

Prediksi	normal	pneumonia
Benar	7	8
Salah	1	0
Total benar		15

$$accuracy = \frac{15}{16} = 0,94$$

Pada hasil yang menunjukan bahwasanya memiliki tingkat akurasi yang tinggi pada saat pengujian menggunakan *framework* Flask. Dan hasil antara kedua arsitektur untuk tingkat akurasi sama, namun citra yang di prediksi salah adalah pengujian citra normal semuanya, karena memang pada saat pengujian *confusion matrix* kelas normal memiliki akurasi yang lebih rendah daripada hasil pneumonia, serta faktor data latih yang lebih banyak pneumonia.

Peneliti menggunakan metode yang mengurutkan citra saat input data ke dalam pengujian. Setelah itu peneliti menemukan kesalahan klasifikasi pada arsitektur AlexNet urutan yang pertama sedangkan, untuk GoogLeNet kesalahan klasifikasi dalam urutan ke 6.

## 5. KESIMPULAN

Penelitian ini menghasilkan dua model dari Algoritma *Convolutional Neural network* yakni arsitektur Alexnet yang memperoleh hasil akurasi dari *confusion matrix* sebesar 0,79 sedangkan arsitektur GoogLeNet memperoleh hasil akurasi dari *confusion matrix* sebesar 0,78 yang secara penalaran hasil arsitektur GoogLeNet harusnya lebih unggul daripada arsitektur AlexNet. Namun pada praktik yang dilakukan peneliti berbeda karena faktor dari *callback* yang digunakan memberhentikan *epoch* yang berjalan dengan parameternya sendiri.

## DAFTAR PUSTAKA

- [1] Indonesian Society Of Respiriology, "Press Release "Perhimpunan Dokter Paru Indonesia ( Pdpi ) Outbreak Pneumonia Di Tiongkok," *Ikatan Dokter Indonesia*, no. 19, pp. 19–22, 2020.
- [2] W. Ratna Hidayani, S.KM., M.SC, "Pneumonia : Epidemiologi, Faktor Risiko Pada Balita," *CV. Pena Persada*, pp. 1–20, 2020.
- [3] 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.
- [4] N. Shukla and K. Fricklas, "Machine Learning With TensorFlow," 2018.
- [5] J. Han, M. Kamber, and J. Pei, *Data mining: Data mining concepts and techniques*. 2011. doi: 10.1109/ICMIRA.2013.45.
- [6] W. You, C. Shen, X. Guo, X. Jiang, J. Shi, and Z. Zhu, "A hybrid technique based on convolutional neural network and support vector regression for intelligent diagnosis of rotating machinery," *Advances in Mechanical Engineering*, vol. 9, no. 6, pp. 1–17, 2017, doi: 10.1177/1687814017704146.
- [7] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sistem dan Teknologi Informasi Indonesia)*, vol. 3, no. 2, pp. 49–56, 2018.
- [8] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, vol. 6, no. 2, pp. 87–92, 2021, [Online]. Available: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2802>
- [9] A. F. Cobantoro, F. Masykur, and K. Sussolaikah, "ERFORMANCE ANALYSIS OF ALEXNET CONVOLUTIONAL NEURAL NETWORK (CNN) ARCHITECTURE WITH IMAGE OBJECTS OF RICE PLANT LEAVES," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 8, no. 2, pp. 111–116, Feb. 2023, doi: 10.33480/jitk.v8i2.4060.
- [10] F. Hafifah, S. Rahman, and M. S. Asih, "Klasifikasi Jenis Kendaraan Pada Jalan Raya Menggunakan Metode Convolutional Neural Networks ( CNN )," vol. 2, no. 5, pp. 292–301, 2021.
- [11] D. D. W., "Jenis-jenis Machine Learning," *medium.com*. Accessed: Apr. 07, 2022. [Online]. Available: <https://medium.com/sysinfo/jenis-jenis-machine-learning-50f918453336>
- [12] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [13] J. M. Czum, "Dive Into Deep Learning," *Journal of the American College of Radiology*, vol. 17, no. 5, pp. 637–638, 2020, doi: 10.1016/j.jacr.2020.02.005.
- [14] P. Mayadewi and E. Rosely, "Prediksi Nilai Proyek Akhir Mahasiswa Menggunakan," *Seminar Nasional Sistem Informasi Indonesia*, no. November, pp. 2–3, 2015.
- [15] K. A. Tait *et al.*, "Intrusion Detection using Machine Learning Techniques: An Experimental Comparison," *2021 International Congress of Advanced Technology and Engineering, ICOTEN 2021*, no. July, 2021, doi: 10.1109/ICOTEN52080.2021.9493543.