

KLASIFIKASI PENYAKIT PNEUMONIA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN OPTIMASI ADAPTIVE MOMENTUM*

Lingga Aji Andika¹, Hasih Pratiwi², and Sri Sulistijowati Handajani³

¹Department of Statistics, Universitas Sebelas Maret (UNS), Indonesia, linggaajiandika@gmail.com

²Department of Statistics, Universitas Sebelas Maret (UNS), Indonesia, hasihpratiwi@gmail.com

³Department of Statistics, Universitas Sebelas Maret (UNS), Indonesia, rr_ssh@staff.uns.ac.id

Indonesian Journal of Statistics and Its Applications (eISSN:2599-0802)

Vol 3 No 3 (2019), 331 - 340

Copyright © 2019 Lingga Aji Andika, Hasih Pratiwi, and Sri Sulistijowati Handajani. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Pneumonia is an infection of the bacterium *Streptococcus pneumoniae* which causes inflammation in the air bag in one or both lungs. Pneumonia is a disease that can spread through the patient's air splashes. Pneumonia can be dangerous because it can cause death, therefore it is necessary to have early detection using chest radiograph images to determine the symptoms of pneumonia. Diagnosis using a chest radiograph image manually by medical personnel or a doctor requires a long time, even difficult to detect pneumonia disease. Convolutional neural network (CNN) is a deep learning method that adopts the performance of human brain neurons called neural network and convolution functions to classify images. CNN can also help classify pneumonia based on chest radiograph images. This study used data from Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification as many as 5860 images entered into two classes, namely normal and pneumonia, then 2400 data samples were taken using simple random sampling. This study uses adaptive momentum optimization (Adam) which serves to improve the accuracy of the model. Adam optimization is a development of existing optimizations such as Stochastic gradient descent (SGD), AdaGard, and RMSProp. The classification results of the models built were 99.98% for training data with 100 epochs, and accuracy in the test data was 78% which means that the model was able to qualify 78% of the test data into normal classes and pneumonia appropriately.

Keywords: adaptive momentum, classification, convolutional neural network, pneumonia.

* Received Aug 2019; Accepted Oct 2019; Published online on Oct 2019

1. Pendahuluan

Paru-paru merupakan organ pada sistem pernapasan manusia yang berfungsi sebagai pertukaran oksigen dengan karbondioksida di dalam darah. Penurunan kualitas udara di dunia termasuk di Indonesia, berdampak pada meningkatnya resiko terkena penyakit paru-paru. Penyakit paru-paru yang sering dijumpai adalah paru-paru basah.

Paru-paru basah atau *pneumonia* adalah bentuk infeksi pernapasan akut yang menyerang paru-paru. Paru-paru terdiri dari kantung-kantung kecil yang disebut alveoli, yang terisi air ketika orang sehat bernafas. Ketika seseorang menderita radang paru-paru, alveoli dipenuhi dengan nanah dan cairan, yang membuat pernafasan terasa menyakitkan dan membatasi asupan oksigen. *Pneumonia* adalah penyebab kematian menular tunggal terbesar pada anak-anak di seluruh dunia. *Pneumonia* menyebabkan 920.136 anak kasus kematian di bawah usia 5 tahun pada 2015, terhitung 16% dari semua anak di bawah lima tahun. *Pneumonia* paling umum dijumpai di Asia Selatan dan Afrika sub-Sahara. *Pneumonia* disebabkan oleh sejumlah infeksi, termasuk virus, bakteri, dan jamur, yang paling umum adalah *streptococcus pneumoniae* (WHO, 2016).

Diagnosa dini *pneumonia* berdampak besar bagi nyawa seorang pasien. Diagnosa *pneumonia* pada umumnya dilakukan secara klinis (gejala fisik oleh dokter). Selain itu, penyakit *pneumonia* juga dapat didiagnosa melalui foto *chest radiograph*, CT scan, dan MRI. Pemeriksaan *chest radiograph* adalah salah satu pemeriksaan pencitraan medis yang paling sering digunakan karena lebih terjangkau. Pembacaan foto *chest radiograph* memiliki kekurangan, yaitu sulit terdeteksinya penyakit, sehingga memerlukan waktu lama sebelum tenaga medis atau dokter mendiagnosis penyakit yang diderita oleh pasien. Salah satu metode untuk mengatasi masalah tersebut adalah dengan mengklasifikasikan citra *chest radiograph* ke dalam kelas tertentu dengan menggunakan *machine learning*. Metode yang digunakan memproses data adalah *multilayer perceptron* (MLP) (Rizal et al., 2017). MLP memiliki kekurangan untuk beberapa jenis data, terutama untuk gambar, akan tetapi MLP tidak diadaptasi dengan baik sehingga kehilangan informasi spasial yang terkandung dalam gambar. *Deep learning* adalah salah satu cabang ilmu dari pembelajaran mesin atau yang kerap disebut sebagai *machine learning*. *Deep learning* merupakan teknik disruptif yang mengubah paradigma lama dalam *machine learning*. *Deep learning* memiliki tingkat akurasi yang jauh lebih tinggi dibandingkan dengan *shallow learning*, yaitu metode *machine learning* yang ada sebelumnya seperti MLP (Cireşan et al., 2012).

Data yang berupa citra *chest radiograph*, merupakan data gambar dua dimensi yang dapat diproses menggunakan *deep learning* dengan metode *Convolutional Neural Network* (CNN) (Santos et al., 2007). CNN adalah jaringan saraf atau *neural network* yang menggunakan konvolusi sebagai pengganti perkalian matriks umum, dimana paling tidak terdapat satu konvolusi di setiap *layer*. CNN mampu mengklasifikasikan citra dengan tingkat akurasi tinggi karena dapat mengurangi sejumlah parameter bebas serta dapat menangani deformasi gambar input seperti translasi, rotasi dan skala. Optimasi pada CNN dapat membantu meningkatkan akurasi, salah satunya adalah *adaptive moments* atau *adam* (Kingma & Ba, 2014).

Saraiva et al. (2019) membahas tentang klasifikasi penyakit pneumonia pada anak-anak dengan menggunakan *convolutional neural network*. Penelitian tersebut menggunakan validasi silang *k-fold* untuk mengevaluasi kapasitas generalisasi model dan bertujuan untuk meningkatkan akurasi dengan validasi silang *k-fold* dengan akurasi rata-rata sebesar 95,30%. Akan tetapi penelitian tersebut belum ada pemilihan model terbaik dengan membandingkan jumlah *epochs* untuk model *training* sehingga didapatkan klasifikasi CNN dengan akurasi tertinggi, selain itu pembangunan arsitektur

model menggunakan *base model* yang sudah ada. Penelitian ini akan dibandingkan jumlah *epochs* untuk mengklasifikasikan penyakit paru-paru dengan citra *chest radiograph* dengan melihat tingkat akurasi tertinggi dari optimasi model yang dibangun serta arsitektur model dari awal.

2. Metodologi

2.1 Bahan dan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang berasal dari Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification (Kermany *et al.*, 2018). Data berupa gambar dengan berbagai ukuran. Data terdiri dari dua kelas yaitu kondisi pneumonia dan kondisi normal dengan jumlah 5860 data.

2.2 Metode Penelitian

Langkah-langkah yang dilakukan untuk mengklasifikasikan penyakit *pneumonia* dengan citra *chest radiograph* menggunakan *convolution neural network* adalah sebagai berikut:

1) Melakukan *preprocessing* data

Sebelum data dianalisis perlu dilakukan *preprocessing* data, yang bertujuan untuk melihat karakteristik data. Karakteristik data merupakan gambaran umum bagaimana komputer membaca sebuah gambar menjadi *array* yang bermakna untuk proses selanjutnya seperti adanya efek spasial dalam data gambar. *Preprocessing* juga membagi data ke dalam tiga set data yaitu *training data*, validasi data, serta *test data* yang bertujuan untuk pemodelan di langkah selanjutnya.

2) Melakukan pemodelan CNN pada data *training*.

Jaringan konvolusional yang juga dikenal sebagai jaringan saraf konvolusional, atau *Convolutional Neural Network* (CNN), adalah jenis jaringan saraf khusus untuk memproses data yang memiliki kemiripan *grid topology*. Nama CNN menunjukkan bahwa jaringan tersebut menggunakan operasi matematika yang disebut konvolusi. CNN merupakan jaringan saraf yang menggunakan konvolusi sebagai ganti dari penerapan matriks umum dimana paling tidak terdapat satu konvolusi di setiap layer (Goodfellow *et al.*, 2016). Dalam matematika, konvolusi adalah operasi matematika pada dua fungsi untuk menghasilkan fungsi ketiga yang mengekspresikan bagaimana bentuk satu dimodifikasi oleh yang lain. Istilah konvolusi mengacu pada fungsi hasil dan proses penghitungannya (Romero *et al.*, 2016).

Sebagai contoh seseorang menembakkan sensor laser untuk melacak sebuah pesawat luar angkasa yang memberikan output tunggal $x(t)$ dimana t adalah waktu ke- t dimana x dan t bernilai riil. Untuk memperoleh perkiraan posisi pesawat ruang angkasa yang tidak terlalu berisik, digunakan rata-rata beberapa pengukuran. Karena, pengukuran yang terbaru lebih relevan, maka rata-rata tertimbang digunakan untuk pembobot pengukuran baru. Fungsi ini disebut fungsi pembobotan $w(a)$ dengan a usia pengukuran. Jika digunakan secara terus menerus, maka didapatkan fungsi baru s yang memberikan estimasi *smooth* tentang posisi pesawat, sehingga persamaan kontinu dapat dituliskan sebagai berikut (Goodfellow *et al.*, 2016):

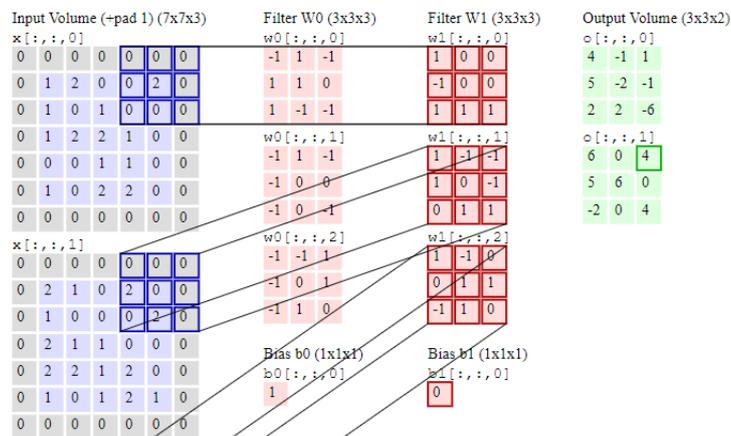
$$s(t) = \int x(a)w(t-a)da$$

Dalam terminologi jaringan konvolusional, fungsi x ke jaringan sering disebut input, fungsi w disebut kernel, dan output dihasilkan terkadang berupa *feature map* atau peta aktivasi (*activation map*) yaitu pemetaan dimana fitur tertentu ditemukan dalam gambar. Karena diasumsikan t dihitung per detik sehingga t adalah bilangan bulat, maka persamaan konvolusi diskrit:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a)$$

Pemodelan data *training* dibangun menggunakan beberapa pengulangan *convolution layer* dan *pooling layer* yang kemudian diakhiri dengan *fully connected layer* untuk membangun arsitektur pemodelan dengan akurasi tinggi. Secara terpisah fungsi masing-masing lapisan dijelaskan sebagai berikut:

- a. Lapisan konvolusi (*convolution layer*) adalah bagian inti dari CNN dimana sebagian komputasi dilakukan di lapisan ini.



Gambar 1: *Convolution Layer* (Li et al., 2019).

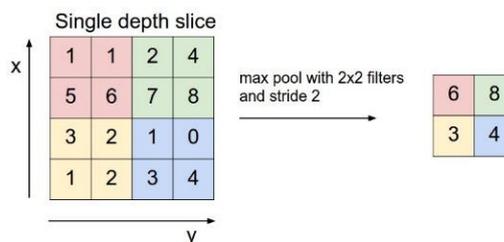
Gambar 1 menunjukkan cara kerja dari konvolusi layer. Output didapat dari konvolusi kernel terhadap bagian dari gambar. Kemudian, kernel bergerak dengan jumlah S piksel, S yang disebut *stride*. Ketika langkahnya kecil, didapat informasi *redundant*. Terkadang input ditambahkan *zero padding* (P), yang merupakan *margin* berisi nilai nol di sekitar gambar untuk mengontrol ukuran output. Diasumsikan bahwa diterapkan K kernel (juga disebut filter), masing-masing berukuran $k \times k$ pada gambar, dimana $k = F$ adalah tingkat spasial. Jika ukuran gambar input adalah $W_i \times H_i \times C_i$ (W_i menunjukkan lebar, H_i tinggi, dan C_i jumlah *channels* atau kedalaman (*depth*), biasanya $C_i = 3$ (Red, Green, Blue)), volume output adalah $W_o \times H_o \times C_o$, dimana C_o sesuai dengan banyaknya kernel K , sehingga didapat ringkasan konvolusi layer:

$$W_o = \frac{W_i - F + 2P}{S} + 1$$

$$H_o = \frac{H_i - F + 2P}{S} + 1$$

$$C_o = K$$

- b. Lapisan *pooling* berfungsi secara progresif mengurangi ukuran representasi spasial sehingga mereduksi jumlah parameter dan perhitungan dalam jaringan yang disebut juga *subsampling*, dan juga mengontrol *overfitting* (Scherer *et al.*, 2010). Pooling layer digunakan secara berkala diantara *convolution layer*. *Max pooling* adalah *pooling layer* yang mengambil nilai maksimum dari setiap operasi kernel dengan input. *Max pooling* lebih banyak digunakan dibandingkan *pooling* yang lain seperti *average pooling*. Gambar 2 menjelaskan penerapan *max pooling*.



dari hasil klasifikasi data *test*. *Confusion matrix* adalah matrix yang merepresentasikan hasil klasifikasi pada suatu dataset (Pedregosa et al., 2011).

Tabel 1: *Confusion Matrix binner*.

Kelas	Positif	Negatif
Positif	Positif Benar (PB)	Negatif Salah (NS)
Negatif	Positif Salah (PS)	Negatif Benar (NB)

Terdapat beberapa rumus umum yang dapat digunakan untuk menghitung performa klasifikasi. Hasil dari nilai *accuracy*, *presision* dan *recall* bisa ditampilkan dalam presentase (Tabel 1).

- a. *Accuracy* adalah jumlah proporsi prediksi yang benar. Adapun rumus perhitungan akurasi dapat dilihat dari persamaan dibawah ini.

$$Accuracy = \frac{PB + NB}{PB + PS + NB + NS}$$

- b. Presisi adalah rasio PB / (PB + PS). Presisi secara intuitif adalah kemampuan *classifier* untuk tidak memberi label positif sebagai sampel yang negatif.
- c. *Recall* atau penarikan kembali adalah rasio PB / (PB + NS). Penarikan secara intuitif adalah kemampuan *classifier* untuk menemukan semua sampel positif.

3. Hasil dan Pembahasan

Berikut adalah hasil dan pembahasan dari masing-masing tahap:

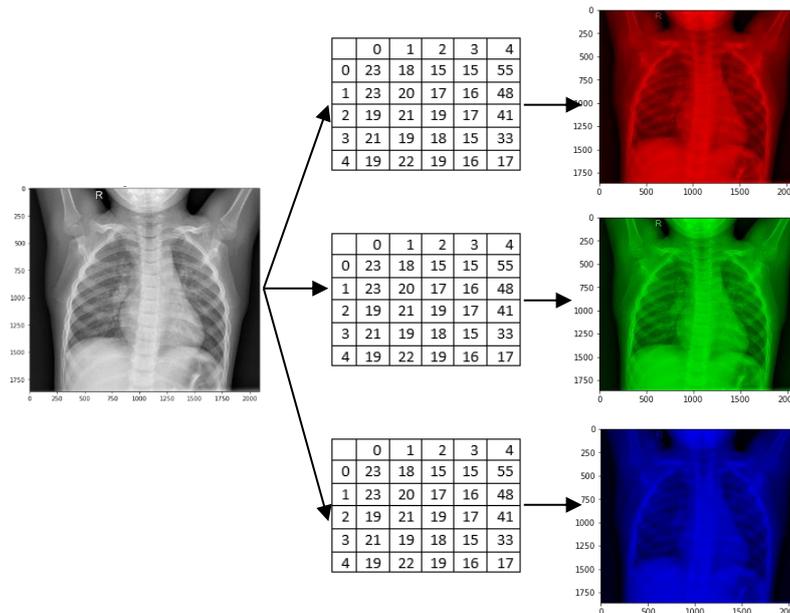
1) Preprocessing Data

- a. Pembagian data. Data mentah yang di dapat kemudian di ambil sampling dengan menggunakan probability sampling yaitu simple random sampling. Tahap preprocessing data sendiri meliputi pemisahan data menjadi data *training*, data validasi, dan data *test* disajikan pada Tabel 2.

Tabel 2: Partisi data.

Bagian	Jumlah Data	Kondisi	Jumlah
Data <i>training</i>	2000	Normal	1000
		<i>Pneumonia</i>	1000
Data validasi	200	Normal	100
		<i>Pneumonia</i>	100
Data <i>test</i>	200	Normal	100
		<i>Pneumonia</i>	100
Total			2400

- b. Konversi ke *array*. Data yang telah dipisahkan ke dalam tiga set data kemudian dikonversi ke dalam *array* terlebih dahulu, hal ini dikarenakan komputer hanya bisa membaca sebuah citra gambar sebagai susunan angka yang kemudian disebut sebagai *array*. Konversi gambar juga akan membagi setiap gambar menjadi tiga bagian warna atau *depth* yaitu *red*, *green*, *blue* (RGB). Gambar 4 adalah sampel dari konversi sebuah citra menjadi *array*, dimana *array* yang ditampilkan adalah 5x5 susunan angka pertama setiap bagian warna. Data dalam bentuk *array* inilah yang akan diproses dalam CNN. *Array* diplotkan kembali menjadi sebuah gambar terpisah berdasarkan bagian warna untuk melihat setiap bagiannya.



Gambar 4: Sampel konversi ke array.

2) Pemodelan CNN

Pembangunan model CNN terdiri dari beberapa tahap penggulangan antara lapisan konvolusi dan lapisan pooling yang diakhiri dengan lapisan *fully connected*. Tabel 3 menjelaskan bahwa model dibangun dari empat kali perulangan lapisan konvolusi dan *pooling* sebelum diakhiri dengan lapisan *fully connected*. Berdasarkan output diatas didapatkan parameter total 88.699.969, parameter yang dilatih 88.699.969 serta tidak ada parameter yang tidak dilatih.

Tabel 3: Pembangunan model CNN.

Layer	Output Shape	Param
Layer konvolusi	(222,222,32)	896
Max pooling	(111,111,32)	0
Layer konvolusi	(109,109,64)	18.496
Max pooling	(54,54,64)	0
Layer konvolusi	(52,52,128)	73.856
Max pooling	(26,26,128)	0
Flatten	(86528)	0
Dropout	(86528)	0
Dense	(1024)	88.605.696
Dense	(1)	1025
Total params		88.699.969
Trainable params		88.699.969
Non-trainable params		0

3) Membandingkan model

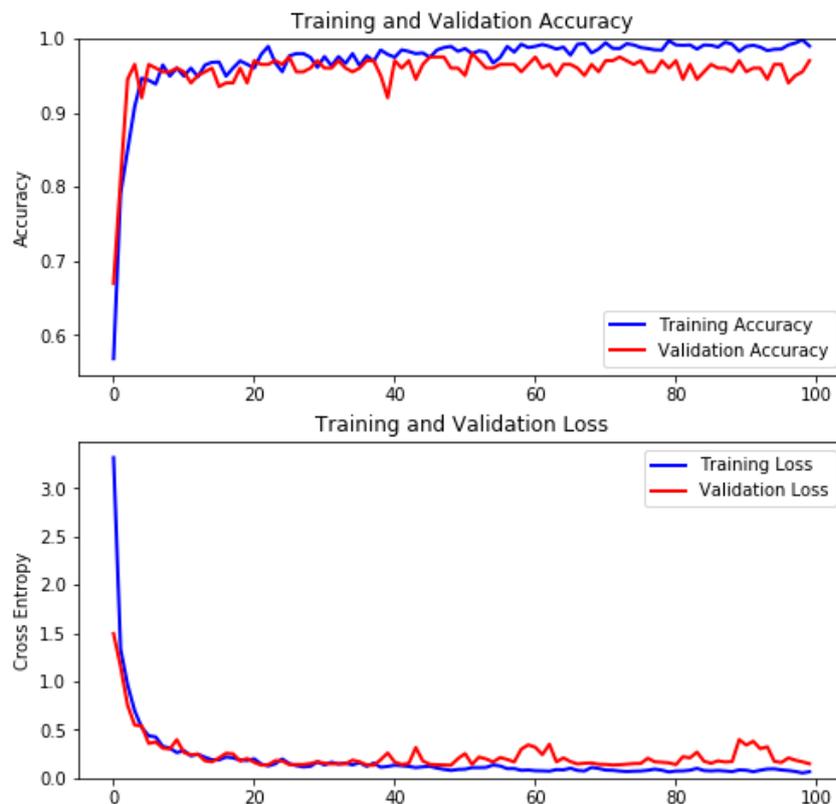
Tahapan selanjutnya adalah pengaplikasian model yang dibentuk ke dalam data *training* serta data validasi dengan beberapa pemilihan banyaknya *epochs* pada saat mulai konvergen. Setiap *epochs* berjalan melalui 16 langkah.

Tabel 4: Perbandingan *epochs*.

Keterangan	Maksimum <i>epochs</i>		
	50	75	100
Akurasi data <i>training</i>	98,26%	99,12%	98,98%
<i>Loss function</i> data <i>training</i>	0.0913	0.0714	0.0646
Akurasi data validasi	96,00%	96.50%	97.00%
<i>Loss function</i> data validasi	0.2019	0.1506	0.1484

Pengaplikasian model ke dalam data *training* dan data validasi dioptimasi dengan menggunakan *adaptive momentum* atau *adam*. *Adam* dipilih karena hasil dari penyempurnaan optimasi dalam *deep learning* yang sudah ada sebelumnya. Optimasi dilakukan untuk meningkatkan *learning rate* yang berdampak pada peningkatan akurasi.

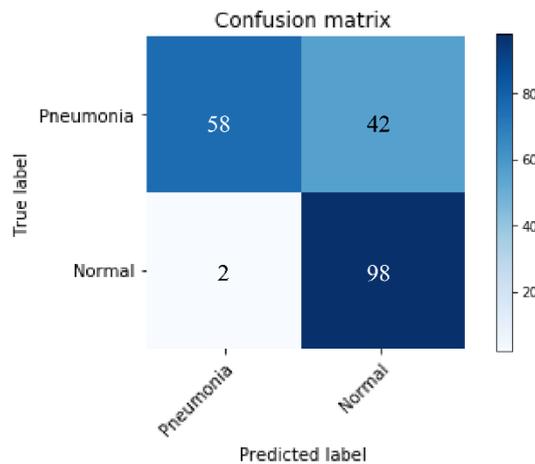
Tabel 4 menampilkan output masing-masing pemilihan *epochs*. Akurasi tertinggi sebesar 99.12% pada *epochs* 75, Sedangkan *loss function* terendah 0.0646 pada data *training* pada *epochs* 100. Akurasi tertinggi sebesar 97,00% dan *loss function* terendah 0,1484 pada data validasi dengan 100 *epochs*, maka model yang dipilih menggunakan 100 *epochs*. Gambar 5 menunjukkan tingkat akurasi dan *loss function* data *training* dan validasi dari perjalanan *epochs* pertama hingga *epochs* terakhir.

Gambar 5: Plot akurasi dan *loss function*

Gambar 5 menjelaskan bahwa akurasi dari model cenderung naik dan *loss function* cenderung menurun untuk data *training*, sedangkan untuk data validasi, akurasi dari model cenderung turun dan *loss function* cenderung naik. Berdasarkan plot akurasi menuju arah konvergen setelah *epochs* ke-lima .

4) Klasifikasi

Model yang telah diperoleh kemudian di uji ke dalam data *test* sehingga didapat output sebagai berikut. Gambar 6 menjelaskan bahwa model yang telah dibangun dapat mengklasifikasi paru-paru normal secara benar sebanyak 98 data dan dua datasalah han, sedangkan untuk paru-paru dengan kondisi *pneumonia*, model mampu mengklasifikasi 58 data secara benar dan 42 data salah. Klasifikasi dari data *test* lebih jelas dapat dilihat dari laporan hasil klasifikasi yang ditunjukkan pada Tabel 5 berikut.



Gambar 6: Confusion Matrix

Tabel 5: Laporan klasifikasi.

	Precision	Recall
Pneumonia	0.97	0.58
Normal	0.70	0.98
Akurasi		0.78

Tabel 5 menjelaskan presisi dari paru-paru *pneumonia* sebesar 97% yang berarti bahwa kemampuan *classifier* untuk tidak memberi label *pneumonia* sebagai sampel normal sebesar 97%, sedangkan untuk normal sebesar 70%. *Recall* pada paru-paru *pneumonia* sebesar 58% yang berarti bahwa kemampuan *classifier* untuk menemukan semua sampel *pneumonia* sebesar 58% .dan untuk paru-paru normal sebesar 98%, Tingkat akurasi secara keseluruhan sebesar 78%. Hasil akurasi lebih kecil dibanding dengan penelitian Saravia, et al. (2019) sebesar 95,30% dikarenakan arsitektur model yang dibangun menggunakan *base model* yang sudah ada.

4. Simpulan

Simpulan dari penelitian ini adalah model yang dibangun dengan menggunakan 100 *epochs* menghasilkan akurasi pada data *training* sebesar 98,98% dan 97,00% pada data validasi. Model yang dibentuk kemudian di uji ke dalam data *test* dengan tingkat akurasi 78% dengan rincian paru-paru normal secara benar diklasifikasikan sebanyak 98 data dan terdapat dua data salah, sedangkan untuk paru-paru dengan kondisi *pneumonia*, model mampu mengklasifikasi 58 data secara benar dan 42 data salah.

Daftar Pustaka

- Al-Waisy, A. S., Qahwaji, R., Ipson, S., Al-Fahdawi, S., & Nagem, T. A. (2018). A multi-biometric iris recognition system based on a deep learning approach. *Pattern Analysis and Applications*, 21(3): 783–802.
- Cireřan, D., Meier, U., & Schmidhuber, J. (2012). *Multi-column deep neural networks for image classification*. Retrieved from IEEE Computer Society Conference on Computer Vision and Pattern Recognition website: <https://arxiv.org/abs/1202.2745>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. Massachusetts (US): MIT press.
- Kermany, D., Zhang, K., & Goldbaum, M. (2018). *Labeled optical coherence tomography (OCT) and chest X-Ray images for classification*, *Mendeley Data*, vol. 2 (2018). Mendeley Data.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations*. Presented at the 3rd International Conference for Learning Representations, San Diego (US). Retrieved from <https://arxiv.org/abs/1412.6980>
- Li, F. F., Johnson, J., & Yeung, S. (2019). *Convolutional neural networks (Lecture notes)*. California (US): Computer Science, Stanford University.
- Oyedotun, O., & Khashman, A. (2017). Iris nevus diagnosis: convolutional neural network and deep belief network. *Turkish Journal of Electrical Engineering & Computer Sciences*, 25(2): 1106–1115.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Dubourg, V. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct): 2825–2830.
- Rizal, A., Hidayat, R., & Nugroho, H. A. (2017). Entropy measurement as features extraction in automatic lung sound classification. *2017 International Conference on Control, Electronics, Renewable Energy and Communications (ICCREC)*, 93–97. Yogyakarta (ID): IEEE.
- Romero, A., Gatta, C., & Camps-Valls, G. (2016). Unsupervised deep feature extraction for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1349–1362.
- Santos, A. dos, Pereira, B. de B., Seixas, J. de, Mello, F. C. Q., & Kritski, A. L. (2007). Neural networks: an application for predicting smear negative pulmonary tuberculosis. In *Advances in statistical methods for the health sciences* (pp. 275–287). Springer.
- Saraiva, A., Ferreira, N., Sousa, L., Carvalho da Costa, N., Sousa, J., Santos, D., ... Soares, S. (2019). Classification of Images of Childhood Pneumonia using Convolutional Neural Networks. *6th International Conference on Bioimaging*, 112–119. <https://doi.org/10.5220/0007404301120119>
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *International Conference on Artificial Neural Networks*, 92–101. Berlin (DE): Springer.
- [WHO] World Health Organization. (2016). *Pneumonia*. Retrieved from <http://www.who.int/en/>