

# Klasifikasi Citra X-Ray COVID-19 Menggunakan *Three-layered* CNN Model

Aaron Berliano Handoko<sup>1</sup>, Ivanna K. Timotius<sup>2</sup>, Darmawan Utomo<sup>3</sup>

<sup>1,3</sup>Program Studi Teknik Komputer,

<sup>2</sup>Program Studi Teknik Elektro,

Fakultas Teknik Elektronika dan Komputer,

Universitas Kristen Satya Wacana, Salatiga

<sup>1</sup>622019007@student.uksw.edu, <sup>3</sup>darmawan.utomo@uksw.edu

<sup>2</sup>Dept. Experimental Therapy,

University Hospital Erlangen (UKer) and Preclinical Experimental Animal Center,

Friedrich-Alexander-University Erlangen-Nürnberg (FAU), 91054 Germany

<sup>2</sup>ivanna.timotius@ieee.org

## Abstrak

Tragedi Covid yang melanda dunia perlu mendapat solusi pendeteksian yang cepat untuk mempermudah pengobatannya. Metode tes PCR jumlah alatnya lebih sedikit dibandingkan dengan mesin X-ray di Indonesia. Oleh karena itu, metode pengklasifikasi gambar X-ray dapat digunakan sebagai solusi alternatif. Pada penelitian ini diusulkan penggunaan model CNN dengan tiga lapisan *convolutional* dan *maxpooling*. Dataset image yang digunakan memiliki 1000 image teridentifikasi Covid dan 3000 image sebagai normal. *Hyperparameter tuning* dilakukan dengan cara membandingkan beberapa kombinasi *hyperparameter*; *learning rate*, *dropout rate* dan *density*. Model terbaik yang didapatkan adalah model tiga lapisan *neural network* dengan *learning rate* = 0,001, *density* = 64 dan *dropout rate* = 0,7. Model ini memiliki rata-rata akurasi sebesar 96% dan jumlah parameter sebanyak 7,1% dibandingkan acuan.

**Kata kunci:** CNN, COVID-19, klasifikasi, *deep neural network*, x-ray

## Abstract

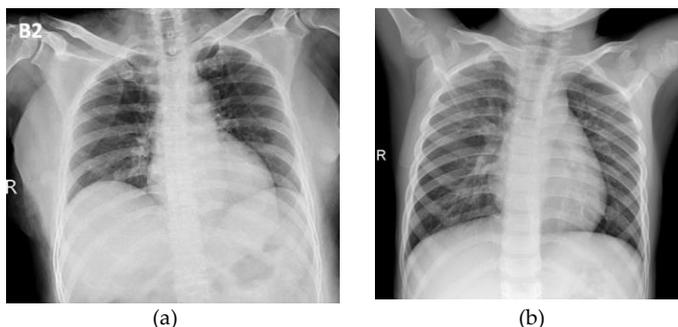
The Covid tragedy that has hit the world needs a solution with fast detection to facilitate its treatment. The PCR test method has fewer tools than X-ray machines in Indonesia. Therefore, the X-ray image classifier method can be optimized as an alternative solution. In this paper, we propose the use of three *convolutional* and *maxpooling* layer CNN model. The unbalanced image dataset has 1000 images identified as Covid and 3000 images as normal. *Hyperparameter tuning* is done by comparing and evaluating the results of models that uses different combinations of hyperparameters dropout rate, learning rate and density. The best model produced is the three-layered neural network model with learning rate = 0.001, density = 64 dan dropout rate = 0.7. This model has an average accuracy of 96% and the number of parameters is only 7.1% compared to the reference.

**Keywords:** Classification, CNN, COVID-19, deep neural network, x-ray

## 1. Pendahuluan

*Coronavirus Disease* (COVID 19) pertama kali muncul pada tahun 2019 di Wuhan, Cina. Berdasarkan *World Health Organization* (WHO), penyakit ini menyerang sistem pernapasan manusia secara akut dengan diikuti gejala seperti demam, batuk kering dan sesak napas [1], [2]. COVID 19 menyebar dengan cepat di seluruh dunia dan mengakibatkan lebih dari 6 juta orang meninggal [3]. Walaupun sudah berlangsung selama kurang lebih dua tahun, virus COVID-19 masih terus melakukan mutasi. Varian terbaru COVID-19 dinamakan varian *omicron*. *Omicron* memiliki tingkat transmisi yang lebih cepat dan mampu berevolusi sehingga dapat bertahan hidup di berbagai kondisi lingkungan [4], [5]. Varian ini juga yang bertanggung jawab dalam meningkatnya *reinfection* atau infeksi kembali pasien yang sudah pernah terinfeksi sebelumnya.

Metode pendeteksian virus COVID-19 yang dianggap efektif saat ini adalah tes *Polymerase Chain Reaction* (PCR) berkala. Namun hasilnya membutuhkan waktu paling cepat sekitar satu hari karena banyaknya sampel yang harus diperiksa dan keterbatasan alat PCR di Indonesia [6]. Metode lain yang dapat digunakan sebagai alternatif adalah dengan menganalisa hasil X-ray paru-paru pasien. Berdasarkan riset dari R. Theodora, pemeriksaan radiologi merupakan sebuah parameter penting untuk menilai perbaikan pasca infeksi SARS-CoV-2 [7]. Akan tetapi untuk membedakan paru-paru pasien COVID-19 (Gambar 1a) dengan normal (Gambar 1b) cukup sulit sehingga diperlukan seorang radioterapis yang handal.



Gambar 1. a. Hasil X-ray pasien COVID-19. b. Hasil X-ray pasien normal

Berdasarkan beberapa penelitian, *machine vision* mampu digunakan untuk mengenali pola hasil X-ray pasien dan mengklasifikasikannya. Abbas *et al.* mengusulkan penggunaan *deep Convolutional Neural Network* (CNN) yang terdiri dari *Decompose*, *Transfer*, dan *Compose* (DeTraC) untuk mengklasifikasi COVID-19 pada X-ray pasien dan mendapatkan akurasi terbaik sebesar 93,1% [8]. Dataset yang digunakan terdiri dari 80 gambar CXR dari Japanese Society of Radiological Technology, gambar CXR Covid-19 dan Sars sebanyak 105 gambar. Penelitian yang dilakukan oleh Ozturk *et al.* membandingkan beberapa algoritma klasifikasi untuk memprediksi COVID-19 [9]. Berdasarkan hasil yang didapat, algoritma CNN memiliki akurasi dan bobot komputasi yang terbaik.

Penelitian yang dilakukan oleh Ayumi dan Nurhaida menggunakan algoritma CNN dengan dua lapis *convolution* dan *maxpooling* untuk mengklasifikasi gambar X-ray COVID-19 [10]. Pada penelitian ini didapatkan f1-score bernilai 96,60%. Selain itu, pada saat evaluasi, mereka tidak memisahkan antara *validation* dan *testing* pada pengujian model arsitekturnya. Model yang terbentuk memiliki 49.571.779 parameter sehingga

membutuhkan komputasi yang besar baik pada saat *training* maupun saat *inferencing*nya. Model ini kurang cocok untuk diterapkan pada lab X-ray rumah sakit yang memiliki komputasi yang terbatas.

Model yang diusulkan pada penelitian ini merupakan model dengan arsitektur CNN yang menggunakan tiga lapisan *convolutional* dan *maxpooling*. Lapisan *convolutional* yang lebih banyak akan meningkatkan pendeteksian detail gambar yang dideteksi namun waktu *training* akan memakan waktu lebih lama. Menurut Tobias, CNN dengan tiga lapis *convolutional* dapat mengklasifikasi gambar *grayscale* dengan baik [11]. Oleh karena itu, digunakan tiga lapisan *convolutional* dan *maxpooling* layer pada penelitian ini.

Model ini kemudian akan dibandingkan dengan model CNN [10] yang menggunakan dua lapisan *convolutional* dan *maxpooling*. Pada penelitian ini akan dilakukan *hyperparameter tuning* pada algoritma CNN untuk mendapatkan model dengan akurasi dan bobot komputasi yang terbaik. Parameter yang diuji terdiri dari *learning rate*, *dropout rate* dan *density*. Model akan dinilai berdasarkan *f1 score*, *precision*, waktu *training* dan juga jumlah parameter model.

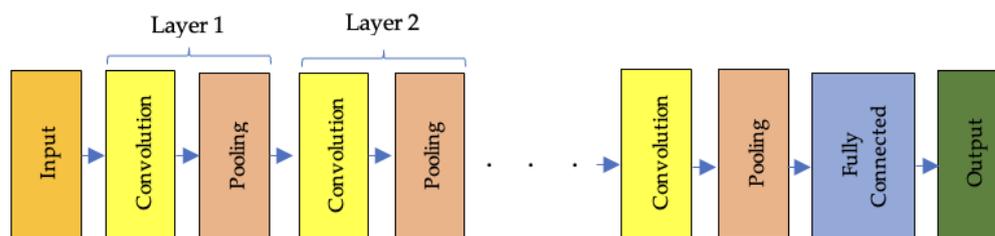
Kontribusi yang dihasilkan pada penelitian ini adalah sebagai berikut:

1. *Three-layered* neural network CNN model untuk mengklasifikasi gambar X-ray COVID-19.
2. Mengusulkan teknik-teknik *Hyperparameter tuning* pada pemodelan CNN untuk mendapatkan model dengan akurasi dan bobot komputasi yang lebih baik.
3. Menyusun model arsitektur yang memiliki nilai akurasi 96% dan *f1 score* COVID sebesar 92% dengan jumlah parameter model yang jauh lebih sedikit dibandingkan model yang dibuat oleh [10].
4. Arsitektur model yang tahan terhadap ketidakseimbangan dataset.

## 2. *Convolutional Neural Network*

*Convolutional Neural Network* (CNN) merupakan algoritma *deep learning* yang digunakan dalam mesin citra [12]. *Deep learning* sendiri adalah sub-bagian dari *machine learning* yang menerapkan konsep sistem neural manusia sehingga komputer dapat menentukan keputusan berdasarkan data yang disediakan [13], [14]. Sudah terdapat banyak publikasi mengenai penggunaan algoritma CNN terutama dalam pendeteksian objek [15], pengklasifikasian objek [16], segmentasi gambar dan bahkan *natural language processing* [17]. Pada dasarnya CNN terdiri dari tiga lapisan yaitu *convolutional layer*, *pooling layer* dan *fully-connected layer* seperti pada Gambar 2.

Algoritma CNN merupakan algoritma yang dapat mengekstraksi fitur dari gambar dan mengurangi banyaknya parameter tanpa adanya penurunan yang berarti terhadap kualitas dari model [18]. Semakin banyak parameter, semakin berat juga bobot komputasi yang dimiliki oleh model [19]. Pengurangan parameter dilakukan di dalam *convolutional layer* dan *pooling layer*. Algoritma CNN juga akan memperhatikan detail kecil yang berada pada sebuah gambar sehingga pengklasifikasian objek dapat dilaksanakan dengan baik.



Gambar 2. Building block algoritma Convolutional Neural Network (CNN) pada umumnya.

### 2.1. Convolutional Layer

*Convolutional Layer* merupakan lapisan pertama pada algoritma CNN. Gambar *input* yang besar akan dibagi menjadi bagian-bagian gambar yang kecil. Pada lapisan ini gambar yang dimasukkan akan disaring dengan mengalikan gambar *input* dengan filter [20]. *Output* dari lapisan ini adalah *feature map* yang akan digunakan pada *activation layer* [21].

### 2.2. Pooling Layer

*Pooling layer* atau *sub-sampling layer* merupakan lapisan yang akan mengurangi dimensi dari *feature map* yang dihasilkan oleh *convolutional layer* [22]. Lapisan ini akan mengambil sebagian dari *feature map* dan menghasilkan satu *output* tergantung dengan tipe *pooling* yang dipakai [23]. Tujuan dari lapisan *pooling* adalah untuk mengurangi parameter yang dikomputasikan.

### 2.3. Fully Connected Layer

Lapisan ini merupakan lapisan terakhir pada algoritma CNN. Pada lapisan ini akan diambil seluruh *neuron* dari lapisan sebelumnya. Kemudian *neuron* ini akan dioperasikan dengan *neuron* pada lapisan saat ini untuk menghasilkan sebuah *output* [20].

## 3. Metode Penelitian

Penelitian dimulai dari persiapan *dataset*, pembentukan CNN model dan kemudian analisis hasil model. Penelitian dilakukan dengan bahasa python dan sistem operasi Macbook Pro M1.

### 3.1. Mempersiapkan Dataset

Gambar X-ray pada artikel ini didapatkan dari *open-source dataset* yang dapat diakses melalui Kaggle [24]. Terdapat 1000 gambar X-ray COVID-19 dan 3000 gambar X-ray normal. Gambar kemudian dibagi secara acak menjadi tiga *dataset* yaitu *training dataset* (60%), *validation dataset* (20%) dan *testing dataset* (20%). *Training dataset* digunakan untuk melatih model dalam mengklasifikasi X-ray, *validation dataset* digunakan untuk memeriksa akurasi pada model setiap *epoch*-nya. Sedangkan *testing dataset* digunakan untuk mengevaluasi presisi dan akurasi untuk mengklasifikasikan gambar X-ray.

### 3.2. Pengolahan Gambar X-ray

Sebelum di-*training*, gambar X-ray disamakan ukurannya menjadi  $200 \times 200$  dengan mode warna RGB (*red, green, blue*). Kemudian gambar dinormalisasikan dengan cara membagikan semua pixel pada gambar dengan 255. Tujuan dari teknik ini adalah untuk

membuat range pixel gambar menjadi 0 sampai 1 sehingga komputasi gambar menjadi lebih mudah [25].

### 3.3. Membentuk Model

*Hyperparameter* yang dianalisa pada artikel ini adalah *learning rate*, *density*, *dropout rate* dan layer CNN model. Terdapat tiga *learning rate* yang dibandingkan yaitu 0,01, 0,001 dan 0,0001. *Learning rate* yang menghasilkan akurasi terbaik akan digunakan untuk *tuning* parameter yang lain. *Density* yang dianalisa terdiri dari 32, 64, 128 dan 256 dan *dropout rate* yang dianalisa adalah 0,3, 0,5, 0,7 dan 0,9. Sedangkan struktur model CNN yang dibandingkan berupa *two-layer convolutional network* dengan *three-layer convolutional network*. *Training* model dilakukan sesuai dengan pseudocode pada Gambar 2. Pada penelitian ini digunakan ukuran *batch* sebesar 32, optimizer *Adam* dan *loss function sparse categorical cross entropy*.

```
flag = layer of neural network CNN {0 = three-layered, 1 =
      two-layered}
drop = dropout rate model
dense = density model

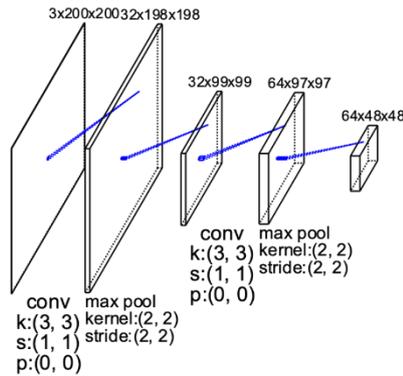
epoch = 30
for flag in [0,1] then
  for drop in [0.3, 0.5, 0.7, 0.9] then
    for dense in [32,64,128,256] then
      if flag = 0 then
        model <- three layered neural network CNN
          dropout rate model <- drop
          density model      <- dense
      else
        model <- three layered neural network CNN
          dropout rate model <- drop
          density model      <- dense
      start timer
      model.fit(epoch = 30)
      stop timer

      print accuracy graph
      print loss graph

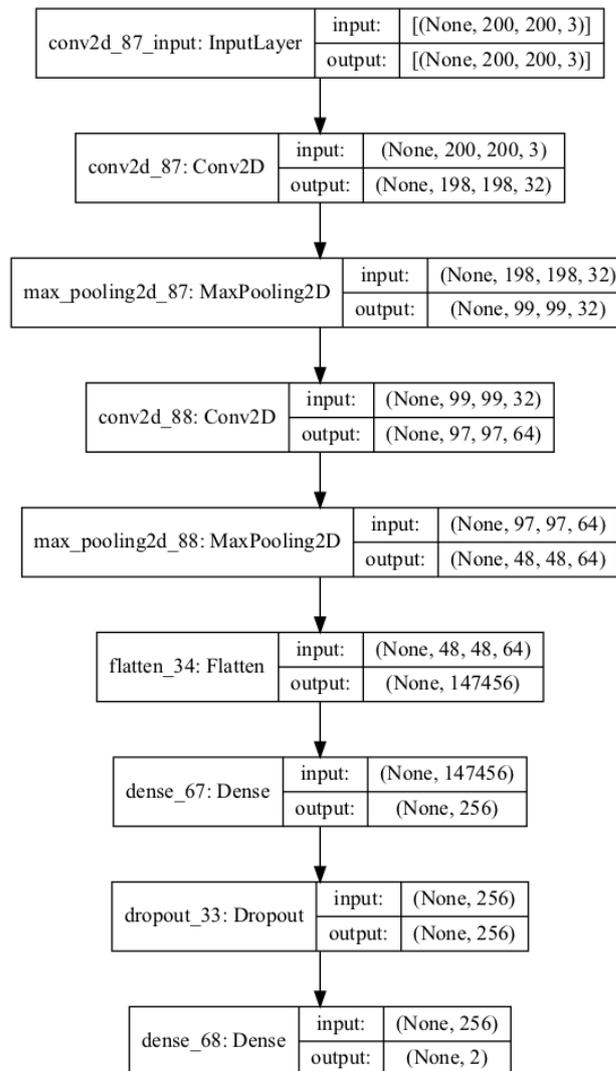
      model.save(str(flag)+'/'+str(drop)+'/'+str(dense)+''.h5')
```

Pseudocode 1. Pseudocode *training* model dengan mengiterasi berbagai macam kombinasi *hyperparameter*

### 3.3.1. Struktur Model *Two-layer Convolutional Network*



Gambar 3. Struktur *convolutional* dan *maxpooling* layer dari *two-layered* CNN model

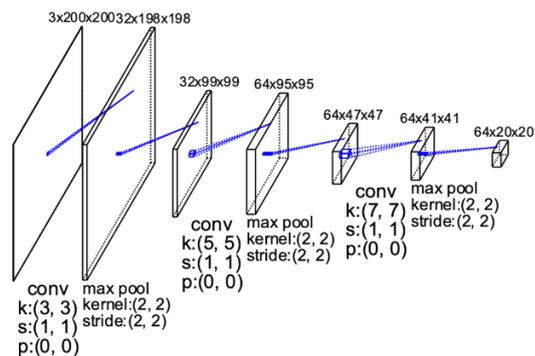


Gambar 4. Struktur layer dari *two-layered* CNN model

Gambar 3 dan 4 memvisualisasikan struktur model untuk *two-layered* CNN model yang digunakan pada penelitian ini. Dapat dilihat pada Gambar 3, *input* yang

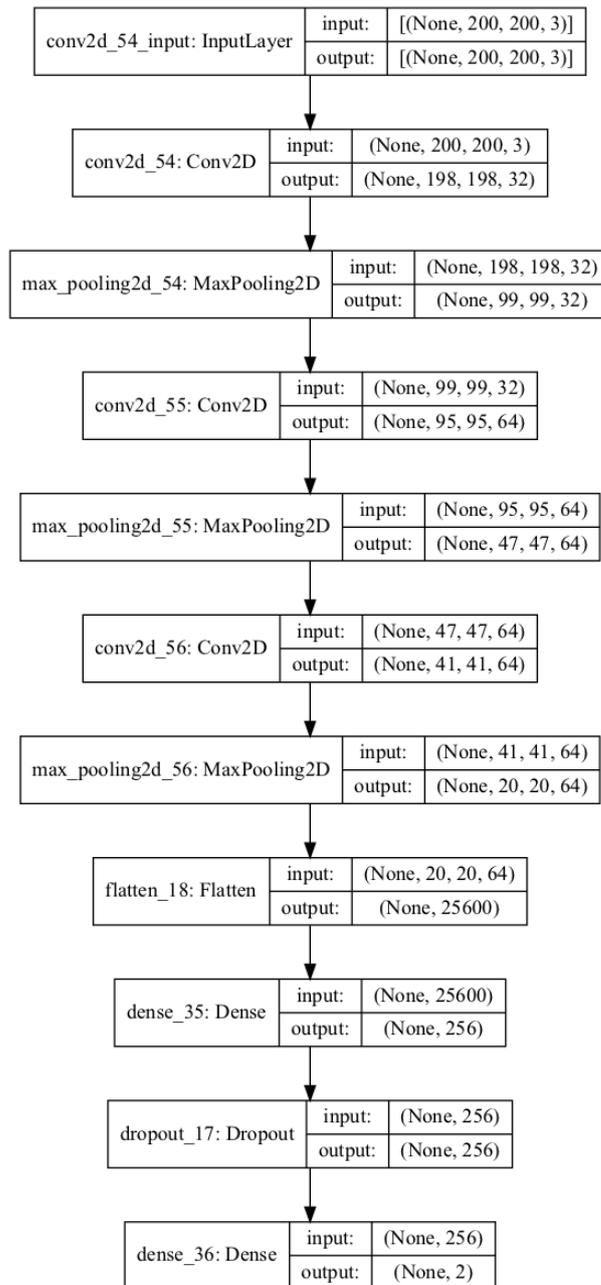
dimasukkan pada model berupa gambar dengan ukuran  $200 \times 200 \times 3$ . Kemudian *input* masuk kedalam *convolutional layer* dengan ukuran kernel  $3 \times 3$ , filter 32 dan activation function *relu*. *Output* dari *convolutional layer* diproses melalui MaxPooling dengan kernel dan stride  $2 \times 2$ . Lalu dilakukan *convolution* kembali dengan ukuran kernel  $3 \times 3$ , filter 64 dan activation *relu* sehingga mengeluarkan *output*  $97 \times 97 \times 64$ . *Output* ini kemudian dilakukan proses MaxPooling dengan kernel dan stride  $2 \times 2$ . Tahap selanjutnya adalah proses *Flatten* dimana *input* akan dijadikan menjadi vektor tunggal. Gambar 4 merupakan contoh model yang menggunakan *density* sebesar 256 dan *dropout rate* sebesar 0,9.

### 3.3.2. Struktur Model Three-layer Convolutional Network



Gambar 5. Struktur *convolutional* dan *maxpooling* layer dari *three-layered* CNN model

Dapat dilihat pada Gambar 5, *input* gambar ( $200 \times 200 \times 3$ ) masuk kedalam *convolutional layer* dengan ukuran kernel  $3 \times 3$ , filter 32 dan activation *relu*. *Output* dari *convolutional layer* kemudian diproses melalui MaxPooling dengan kernel dan stride  $2 \times 2$ . Lalu dilakukan *convolution* kembali dengan ukuran kernel  $5 \times 5$ , filter 32 dan activation *relu*. *Output* proses ini kemudian dilakukan MaxPooling dengan kernel dan stride  $2 \times 2$ . Kemudian dilakukan *convolution* kembali dengan kernel *convolution* sebesar  $7 \times 7$  dan filter 64. Maxpooling juga dilakukan kembali dengan kernel dan stride  $2 \times 2$ . Tahap selanjutnya adalah proses *Flatten*, *dense* dan *dropout*. Gambar 6 merupakan contoh model yang menggunakan *density* sebesar 256 dan *dropout rate* sebesar 0,9.



Gambar 6. Three-layer Convolutional Network Model Summary

### 3.4. Evaluasi Hasil Model

Hasil model dievaluasi berdasarkan akurasi yang didapatkan serta waktu yang dibutuhkan untuk men-*training* model. Akurasi model didapatkan dari *confusion matrix* dan *classification report* dari model tersebut. Menurut hasil akurasi yang didapatkan, diambil model yang terbaik untuk *two-layered* dan *three-layered convolutional network*. Kedua model ini kemudian dilakukan *testing* kembali, dalam 5 kelompok yang setiap kelompoknya berisi 144 gambar X-ray COVID-19 dan 144 gambar X-ray normal. Kemudian data akurasi yang didapat dilakukan analisa rata-rata, standard error of mean (SEM), dan t-test.

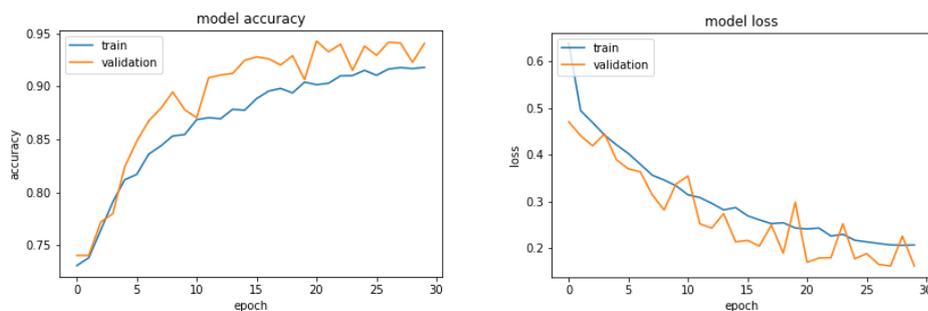
## 4. Hasil dan Pembahasan

### 4.1. Learning rate

Pada percobaan ini digunakan *epoch* sebanyak 30 dan struktur *two-layered convolutional neural network*. Tabel 1 menunjukkan bahwa *learning rate* 0,001 memiliki akurasi f1 score yang terbaik diantara *learning rate* yang lain. Oleh karena *dataset* yang digunakan memiliki data yang tidak seimbang maka evaluasi hasil perlu menggunakan F1 score. F1 score merupakan perbandingan rata-rata presisi dan recall yang dibobotkan. Selain itu *learning rate* ini juga memiliki waktu *training* yang paling cepat diantara yang lain (*training* dilakukan pada sistem M1).

Tabel 1. Hasil percobaan *learning rate*

Learning Rate	Waktu <i>training</i> (detik)	Akurasi (f1 score)
0,01	718,02	0,78
0,001	710,29	0,92
0,0001	711,82	0,86



Gambar 7. Grafik *accuracy* dan *loss* pada *learning rate* 0,001

Pada grafik akurasi, beberapa garis *train* lebih rendah dari garis *validation* (Gambar 7). Hal ini disebabkan karena model memiliki *dropout rate*. Agar memastikan bahwa hasil yang didapatkan merupakan hasil yang *convergent* maka dilakukan *training* kembali dengan menggunakan 50 *epoch*. Hasil dari *training* ini dapat dilihat pada Tabel 2.

Tabel 2. Hasil percobaan *learning rate*

Learning Rate	Waktu <i>training</i> (detik)	Akurasi (f1 score)
0,01	1250,89	0,82
0,001	1233,89	0,92
0,0001	1209,36	0,91

Berdasarkan hasil pada Tabel 2 dapat dilihat bahwa model dengan *learning rate* 0,001 masih memiliki akurasi yang paling baik. Oleh karena hasil yang didapatkan merupakan 92% atau serupa dengan hasil pada Tabel 1 maka dinyatakan bahwa hasil pada *epoch* 30 sudah *convergent*. Walaupun hasil dari *epoch* 50 lebih baik dari *epoch* 30, namun peningkatannya tidak signifikan, hanya meningkat 1% saja dan membutuhkan waktu yang dua kali lebih lama. Oleh karena itu, penelitian *hyperparameter* selanjutnya akan menggunakan *learning rate* 0,001 dengan *epoch* 30.

#### 4.2. Hasil Hyperparamater Testing

Dari 32 model yang terbuat, dinyatakan bahwa model *three-layered neural network* dengan *dropout* sebesar 0,7 dan *density* sebesar 64 merupakan model CNN yang terbaik untuk mengklasifikasikan gambar X-ray. Model memiliki akurasi sebesar 96% dan f1-score sebesar 92% (covid). Dapat terlihat di Tabel 3 bahwa terdapat model lain yang memiliki akurasi sebesar 96% dan f1-score senilai 92%, namun model ini membutuhkan waktu *training* yang lebih lama.

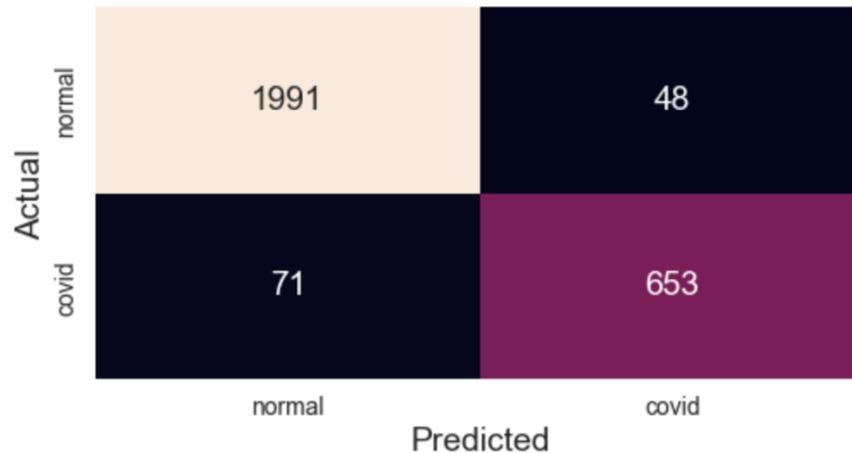
Tabel 3. Lima model dengan akurasi terbaik

Model	Accuracy	F1-score (covid)	Waktu Training (s)
Two-layer convolutional network; Drop: 0,5; Dense: 128	94%	89%	2465,98
Three-layer convolutional network; Drop: 0,5; Dense: 64	96%	91%	1573,36
Three-layer convolutional network; Drop: 0,7; Dense: 32	96%	91%	1585,58
Three-layer convolutional network; Drop: 0,7; Dense: 64	96%	92%	1574,71
Three-layer convolutional network; Drop: 0,7; Dense: 256	96%	92%	1610,78

Dapat dilihat pada classification report (Gambar 8) bahwa tingkat kepresisian yang dihasilkan oleh model terbaik untuk X-ray normal mencapai 0.97 sedangkan kepresisian untuk Covid mencapai 0.92. Hasil akurasi yang didapat lebih tinggi dibandingkan akurasi yang didapatkan oleh Abbas [8]. Selain itu banyaknya parameter yang digunakan oleh model sebanyak 3,530,114 dengan waktu *training* selama 1573 sekon. Bobot komputasi untuk proposal arsitektur model kami ini hanya 7,1% dari model yang diusulkan oleh [10] sehingga relatif jauh lebih cepat baik untuk *training* maupun *inferencing*. Selain itu, dataset yang digunakan oleh [10] memiliki rasio jumlah *image* Covid dibandingkan normal dengan rasio 1200:1341 atau hampir 1:1. Sedangkan dataset untuk percobaan kami memiliki rasio 1000:3000 atau 1:3. Rasio yang makin kecil menunjukkan *image* normal lebih dominan dibandingkan dengan *image* Covid. Meskipun *image* Covid lebih sulit untuk dideteksi, arsitektur yang kami usulkan menunjukkan unjuk kerja yang menyamai kinerja dari rasio 1200:1341 [10]. Dari teknik hyperparameter tuning yang kami usulkan juga menunjukkan bahwa jumlah epoch untuk *training* hanya sebanyak 30 lebih kecil dibandingkan dengan 49 [10].

Classification Report				
	precision	recall	f1-score	support
normal	0.97	0.97	0.97	2039
covid	0.92	0.92	0.92	724
accuracy			0.96	2763
macro avg	0.95	0.94	0.95	2763
weighted avg	0.96	0.96	0.96	2763

Gambar 8. Classification Report model three-layered neural network model dengan dropout sebesar 0,7 dan density sebesar 64.



Gambar 9. Confusion Matrix model *three-layered neural network* model dengan *dropout* sebesar 0,7 dan *density* sebesar 64.

#### 4.3. Perbedaan *Two-layered* dan *Three-layered* Neural Network

*Two-layered* neural network yang memiliki akurasi terbaik memiliki *dense* = 128 dan *dropout rate* = 0,5. Sedangkan akurasi terbaik model *three-layered* neural network memiliki *dense* = 64 dan *dropout rate* = 0,7.

Tabel 4. Perbandingan *two-layered* dan *three-layered* neural network

Akurasi	<i>Two-layered</i>	<i>Three-layered</i>
Rata-Rata	0,93	0,94
Standard Deviasi	1,225	1,871
SEM	0,447	0,683

Dapat terlihat pada Tabel 4, rata-rata akurasi dari model *three-layered* neural network lebih tinggi 1% dari pada *two-layered* neural network. Namun perbedaan yang ada tidak signifikan karena p-value dari kedua data bernilai 0,347 yaitu lebih dari 0,05.

## 5. Kesimpulan dan Saran

Arsitektur model yang kami usulkan menggunakan model CNN yang memiliki struktur *three layered CNN* dengan *learning rate* sebesar 0.001, *density* sebesar 64 dan *dropout rate* sebesar 0,7 memiliki akurasi dan waktu *training* terbaik di antara model lain yang sudah diuji. Rata-rata akurasi yang didapatkan sebesar 96% dengan nilai f1-score sebesar 92%. Selain itu waktu yang dibutuhkan untuk melakukan *training* selama 1574 sekon atau sekitar 26 menit. Model *three-layered* memiliki rata-rata akurasi 1% lebih tinggi dari *two-layered* sehingga perbedaan diantara keduanya tidak signifikan. Jumlah parameter pada arsitektur model ini hanya 7,1% dibandingkan dengan acuan serta tahan terhadap dataset yang tidak seimbang.

Untuk penelitian selanjutnya perlu diteliti algoritma CNN yang memiliki kombinasi lapisan *neural network* yang berbeda. Selain itu klasifikasi tingkat keparahan pasien COVID-19 perlu diteliti, sehingga pasien dapat mendapatkan pertolongan yang tepat.

## Daftar Pustaka

- [1] World Health Organization, "Pertanyaan dan jawaban: Bagaimana COVID-19 ditularkan?," WHO, 2019. <https://www.who.int/indonesia/news/novel-coronavirus/qa/qa-how-is-covid-19-transmitted> (accessed Nov. 21, 2021).
- [2] J. Elliott et al., "Predictive symptoms for COVID-19 in the community: REACT-1 study of over 1 million people," *PLoS Medicine*, vol. 18, no. 9, Sep. 2021, doi: 10.1371/journal.pmed.1003777.
- [3] Worldometer, "COVID-19 Coronavirus Pandemic," Nov. 21, 2021. <https://www.worldometers.info/coronavirus/> (accessed Nov. 21, 2021).
- [4] B. Christie, "Covid-19: Early studies give hope omicron is milder than other variants," *BMJ*, vol. 375, 2021, doi: 10.1136/bmj.n3144.
- [5] V. Thakur and R. K. Ratho, "OMICRON (B.1.1.529): A new SARS-CoV-2 variant of concern mounting worldwide fear," *Journal of Medical Virology*. John Wiley and Sons Inc, 2021. doi: 10.1002/jmv.27541.
- [6] Dr. Fadhli Rizal Makarim, "Ketahui Perbedaan dari Swab Test Antigen dan PCR," *Halodoc*, Sep. 27, 2021. <https://www.halodoc.com/artikel/ketahui-perbedaan-dari-swab-test-antigen-dan-pcr> (accessed Feb. 17, 2022).
- [7] R. Theodora, H. Hendsun, Y. Firmansyah, E. Destra, and D. Gosal, "Periodic Q-PCR or Chest X Ray - Which is more Important for Monitoring Post COVID-19 Infection Case? (Case Report Study)," 2021.
- [8] A. Abbas, M. M. Abdelsamea, and M. M. Gaber, "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network," *Applied Intelligence*, vol. 51, no. 2, pp. 854–864, 2021, doi: 10.1007/s10489-020-01829-7.
- [9] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in Biology and Medicine*, vol. 121, p. 103792, 2020, doi: <https://doi.org/10.1016/j.combiomed.2020.103792>.
- [10] V. Ayumi and I. Nurhaida, "Klasifikasi Chest X-Ray Images Berdasarkan Kriteria Gejala Covid-19 Menggunakan Convolutional Neural Network Article Info ABSTRAK," *JSAI: Journal Scientific and Applied Informatics*, vol. 4, no. 2, 2021, doi: 10.36085.
- [11] T. Hinz, P. Barros, and S. Wermter, "The Effects of Regularization on Learning Facial Expressions with Convolutional Neural Networks," 2016, pp. 80–87. doi: 10.1007/978-3-319-44781-0\_10.
- [12] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology," *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, 2018, doi: 10.1007/s13244-018-0639-9.
- [13] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *CoRR*, vol. abs/2104.05314, 2021, [Online]. Available: <https://arxiv.org/abs/2104.05314>
- [14] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [15] R. Chauhan, K. Ghanshala, and R. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition." 2018. doi: 10.1109/ICSCCC.2018.8703316.
- [16] P. Lakhani and B. Sundaram, "Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural

- Networks,” *Radiology*, vol. 284, no. 2, pp. 574–582, Aug. 2017, doi: 10.1148/radiol.2017162326.
- [17] M. C. Chen et al., “Deep Learning to Classify Radiology Free-Text Reports,” *Radiology*, vol. 286, no. 3, pp. 845–852, Mar. 2018, doi: 10.1148/radiol.2017171115.
- [18] P. Mahesh, Y. G. Prathyusha, B. Sahithi, and S. Nagendram, “Covid-19 Detection from Chest X-Ray using Convolution Neural Networks,” *Journal of Physics: Conference Series*, vol. 1804, no. 1, p. 012197, 2021, doi: 10.1088/1742-6596/1804/1/012197.
- [19] C. W. Wu, “ProdSumNet: reducing model parameters in deep neural networks via product-of-sums matrix decompositions,” *CoRR*, vol. abs/1809.02209, 2018, [Online]. Available: <http://arxiv.org/abs/1809.02209>
- [20] F. Sultana, A. Sufian, and P. Dutta, “Advancements in Image Classification using Convolutional Neural Network,” May 2019, doi: 10.1109/ICRCICN.2018.8718718.
- [21] K. O’Shea and R. Nash, “An Introduction to Convolutional Neural Networks,” *ArXiv e-prints*, Nov. 2015.
- [22] M. Ahmadi, S. Vakili, J. M. P. Langlois, and W. Gross, “Power Reduction in CNN Pooling Layers with a Preliminary Partial Computation Strategy,” in 2018 16th IEEE International New Circuits and Systems Conference (NEWCAS), 2018, pp. 125–129. doi: 10.1109/NEWCAS.2018.8585433.
- [23] H. Gholamalinezhad and H. Khosravi, “Pooling Methods in Deep Neural Networks, a Review,” 2020.
- [24] Tawsifur Rahman, “Covid-19 Radiography Database,” *Kaggle*, 2021. <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database> (accessed Oct. 17, 2021).
- [25] K.-M. Koo and E.-Y. Cha, “Image recognition performance enhancements using image normalization,” *Human-centric Computing and Information Sciences*, vol. 7, no. 1, p. 33, 2017, doi: 10.1186/s13673-017-0114-5.

