

## KLASIFIKASI PNEUMONIA CHEST X-RAY DENGAN ARSITEKTUR INCEPTIONRESNET-V2

Indra Bakti<sup>1</sup> (\*)

<sup>1</sup> Institut Teknologi dan Bisnis Ahmad Dahlan, Jakarta

### Abstract

In the last century, the use utilization of machine learning, especially the Convolution Neural Network (CNN) has helped the world of health (medicine). Through action research on image datasets, CNN was successful and able to show classification or grouping based on the same characteristics and properties on unlabeled images with higher accuracy and faster than other machine learning methods. This study aims to optimize two CNN architectures (InceptionResNet-V2, and MobileNet-V2) to classify Covid-19 disease, by training 4000 Chest x-ray image datasets. The accuracy test results from InceptionResNet- V2 yield 98%, and MobileNet-V2 yield 93%. with the precision of each class of the CNN InceptionRestNet-V2 architecture is Covid (99%), Lung\_Opacity (97%), Normal (99%), Viral\_Pneumonia (99%).

**Kata Kunci:** InceptionResNet, MobileNet, Convolution Neral Network, Chest X-Ray.

Juli - Desember 2022, Vol 3 (2) : hlm 107-121  
©2022 Institut Teknologi dan Bisnis Ahmad Dahlan.  
All rights reserved


(\*) Korespondensi: [indra.chufran@gmail.com](mailto:indra.chufran@gmail.com) (Indra Bakti)

## PENDAHULUAN

Pasca tsunami di India (Maret 2021) mulai menimbulkan efek di beberapa negara yang berdekatan dengan India. Adanya varian baru covid-19 dengan kemampuan sebar sangat tinggi, telah memecahkan rekor tingkat kematian tertinggi di dunia. Dalam sehari sekitar 400.000 lebih pasien terkonfirmasi positif di India, telah melumpuhkan lembaga medis dan tenaga kesehatan dalam menangani jumlah pasien yang sangat besar.

Tanggal 23 Juni 2021 Pemerintah Indonesia melaporkan jumlah kasus terkonfirmasi Covid-19 mencapai 2.033.421 jiwa. Hal ini berdampak pada kebijakan Pemerintah Hong Kong melarang seluruh penerbangan dari Indonesia. Larangan itu menyusul status Indonesia yang berubah menjadi negara A1 (Extremly high risk).

Timbulnya varian baru covid-19 tidak hanya sebaran yang cepat dan masif, tapi juga berdampak pada usia muda. Peningkatan kasus baru terhadap bayi dibawah lima tahun (BALITA) dan juga pada anak-anak mulai mendominasi (Gambar 1). Lembaga kesehatan (rumah sakit) mulai kewalahan dalam mengani jumlah pasien. Misalnya, RSUD dr Chasbullah Abdulmadjid Kota Bekasi, pasien menjalani pengobatan di pekarangan rumah sakit (menggunakan tenda darurat).



Gambar 1. Kelompok umur positif covid-19.

Diagnosa covid-19 secara akurat dapat dilakukan dari image chest x-ray, namun memerlukan para medis dengan keahlian khusus untuk dapat membaca data image tersebut. Karena terbatasnya jumlah para medis ini, menjadikan waktu lama (1-2 minggu) untuk dapat memperoleh hasil diagnosa.

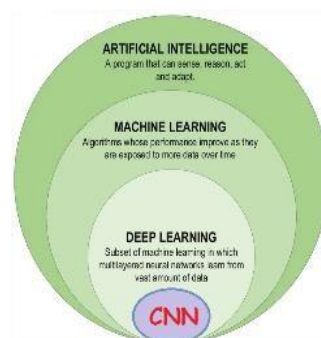
Teknologi intelegensi artifisial atau Artificial Intelligence (AI) khususnya metode Convolution Neural Network (CNN), mampu memprediksi image chest x-ray terhadap penyakit covid-19. Penelitian ini bertujuan memperoleh hasil terbaik pada 2 arsitektur CNN untuk mendeteksi covid-19 dari image chest x-ray.

Penelitian ini bertujuan untuk mendeteksi Viral Pneumonia dari image chest x-ray dengan Arsitektur InceptionResNet-V2. Dimana hasil penelitiannya dapat dilihat pada tabel.3 Hasil Presisi Testing. Sedangkan untuk data set inputnya diperoleh dari <https://www.kaggle.com>. Kita ketahui Pneumonia merupakan penyakit infeksi saluran pernapasan akut yang disebabkan oleh bakteri atau jamur pathogen dan virus. Infeksi ini memberi dampak pada satu atau kedua paru-paru kita dan dapat mengakibatkan efek ringan sampai mengancam jiwa segala usia. Penyakit menular ini menyebabkan kematian terbesar di dunia pada anak-anak; dimana 15% kematian anak-anak tahun 2017, data dari statistik Organisasi Kesehatan Dunia (WHO) dan di antara sumber yang mungkin adalah bakteri dan virus (penyebab infeksi pneumonia).

## METODE

Era teknologi saat ini hampir semuanya melibatkan artificial intelligence (AI) dan deep learning (DL) adalah teknik yang paling banyak dipergunakan dalam pendekatan komputasi dalam bidang Machine Learning (ML). Banyak aplikasi yang dibentuk dengan melibatkan ML. Jenis DL yang paling luas pemanfaatannya dalam kehidupan manusia adalah Convolutional Neural Network (CNN).


Lapisan yang dalam dibandingkan dengan ML lainnya, menjadikan metode ini masuk dalam kategori DL. Kemampuan untuk dapat membedakan objek image, maka teknik ini lebih dikenal dengan CNN (Gambar 2). Beberapa proses dan istilah dalam CNN akan dijelaskan secara singkat pada sub bagian ini.



Gambar 2. Klasifikasi CNN dalam AI


## Convolutional Neural Network

Pemikiran awal Convolutional Neural Network adalah jaringan saraf (neuron) di manusia dan binatang. CNN terdiri dari tumpukan convolutional layer dengan parameter yang berbeda-beda (filter, padding, stride dan lain-lain). Setiap input disusun dalam bentuk matrik tiga dimensi yaitu height (tinggi), width (lebar) dan depth (kedalaman), umumnya nilai height sama dengan nilai width. Untuk input matrik RGB maka nilai channel adalah channel menyatakan nilai depth dalam matrik tersebut. Akhir dari rangkaian lapisan CNN menghasilkan model kernel, kemudian dilanjutkan dengan proses fully connected. Fully Connected bertujuan untuk mengklasifikasikan image dari suatu label tertentu. (Gambar 3).



```
cnn_model = models.Sequential()
```

```
cnn_model.add(layers.Conv2D(32,(3,3), activation='relu', input_shape=(6,6,3)))
```

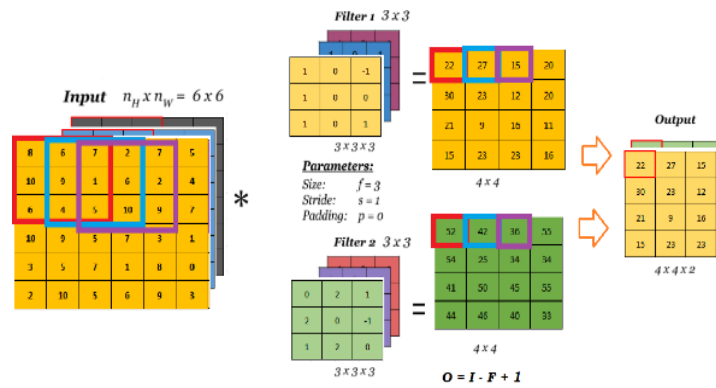


```
cnn_model = models.Sequential()
cnn_model.add(layers.Conv2D(32,(3,3), activation='relu', input_shape=(39,39,3)))
cnn_model.add(layers.Conv2D(64,(5,5), activation='relu'))
cnn_model.add(layers.Conv2D(64,(5,5), activation='relu'))
cnn_model.add(layers.Flatten()).
```

Gambar 3. Proses konvolusi (atas) yang merupakan bagian dari lapisan CNN secara keseluruhan (bawah).

## Proses Konvolusi

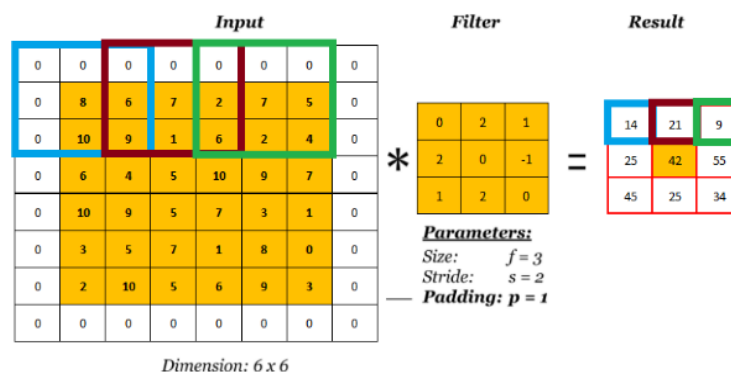
Proses konvolusi merupakan perhitungan dot product antara matrik input dan matrik filter. Matrik filter adalah matrik segi empat (height=width) yang merupakan kumpulan nilai bobot (weight), kadang juga disebut juga sebagai matrik kernel. Ukuran height dan width selalu lebih kecil dari input, tapi nilai depth (channel) sama dengan depth input. Dalam proses konvolusi umumnya menggunakan lebih dari satu jenis matrik kernel (filter 1, filter 2, dan seterusnya). Ukuran matrik output untuk baris dan kolom dapat digunakan ketentuan  $O = I - F + 1$ . (Gambar 4).



Gambar 4. Detail proses konvolusi

## Proses Stride

Proses stride sebenarnya adalah bagian dari proses konvolusi itu sendiri. Matrik filter akan melakukan scanning terhadap matrik input, dengan cara melakukan konvolusi kedua matrik tersebut sesuai ukuran matrik filter. Setelah proses pertama selesai dilanjutkan dengan proses konvolusi kedua dengan menggerakkan matrik input (matrik input ke dua) yang akan di konvolusi dengan matrik filter. Pergeseran matrik input pertama dan kedua adalah sesuai dengan nilai stride yang ditentukan sebagai parameter dalam tiap lapisan. Proses ini diulang untuk konvolusi selanjutnya, sehingga dihasilkan matrik dengan ukuran yang lebih kecil. (Gambar 5).




Gambar 5. Stride dan Padding

## Proses Padding

Padding adalah proses penambahan nilai yang besar sama disetiap sisi image input (biasanya nilai 0 atau satu). Walaupun matrik input menjadi berukuran lebih besar dari semula, namun dalam proses konvolusi akan tetap lebih kecil dari matrik input aslinya. Tujuan dari padding adalah memberikan batasan yang lebih jelas dari suatu image, sehingga proses dapat menjadi lebih focus. Padding kadang juga dipergunakan untuk menyesuaikan ukuran matrik output dengan cara menambah nilai di tiap sisi image sehingga sesuai dengan matrik input yang akan digunakan pada lapisan convultional selanjutnya. (Gambar 5).

## Pooling

Sebenarnya proses pooling identik dengan pengambilan sample data dalam statistik, bedanya dalam pooling tidak ada informasi hilang. Pooling bertujuan untuk memperkecil ukuran matrik agar perhitungan yang dilakukan mesin menjadi lebih cepat. Terdapat banyak jenis pooling, tapi yang umum dipergunakan adalah max pooling dan average pooling. Max pooling adalah mengambil nilai terbesar dalam ukuran matrik tertentu, sedangkan average pooling adalah mengambil nilai rata-rata dalam ukuran matrik tertentu. (Gambar 5a).



Gambar 5a. Proses pooling

## Actifation Function


Fungsi aktivasi diberikan setelah proses pooling, tujuannya agar nilai yang dihasilkan berada dalam rentang nilai tertentu (biasanya berkisar 0 sampai 1) dan juga berfungsi mengambil keputusan untuk mengambil hasil yang sesuai dan menghilangkan hasil yang tidak diinginkan (kurang baik), memetakan input ke output yang tidak linier, memberikan kemampuan belajar yang lebih kompleks. Fungsi aktifvasi juga memiliki kemampuan untuk dapat membedakan feature-feature yang sangat penting.

Activation function	Equation	Example	1D Graph
Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer Neural Networks	
Rectifier, ReLU (Rectified Linear Unit)	$\phi(z) = \max(0, z)$	Multi-layer Neural Networks	
Rectifier, softplus	$\phi(z) = \ln(1 + e^z)$	Multi-layer Neural Networks	

Gambar 6. Jenis fungsi aktivasi

## Fully Connected Layer (FC)

Proses ini berada di akhir tiap lapisan CNN, dinamakan fully connected karena semua neuron (node) terhubung dengan neuron di lapisan sebelum dan sesudahnya. FC berfungsi sebagai klasifikasi, proses ini secara teknis ini tidak lain adalah metode lapisan neural network conventional (feed forward neural network), untuk jelasnya dapat dilihat pada gambar 7.




Gambar 7. Jaringan fully connected (FC)

## Arsitektur CNN

Dari kompetisi yang dilakukan ImageNet Large Scale Visual Recognition Challenge (ILSVRC), terdapat banyak arsitektur CNN yang sudah diciptakan sebagai upaya meningkatkan akurasi melalui pengujian input dataset tertentu yang dijadikan sebagai standar (MNIST [7], imagenet, coconut dll) (Gambar 8). Namun banyak arsitektur lebih cenderung menambah lapisan menjadi sangat dalam ketimbang merancang suatu design struktur dengan metode baru. Hal ini mengakibatkan diperlukannya performansi computer yang tinggi untuk dapat menjalankan arsitektur tersebut [13].

Dalam penelitian ini akan dicoba beberapa arsitektur yang mampu dilaksanakan oleh komputer yang ada, dengan sedikit melakukan penyesuaian agar memperoleh hasil yang diinginkan. Dua arsitektur yang dipergunakan dan dibandingkan dalam penelitian ini adalah InceptionResNet-V2, dan MobileNet-V2. Arsitektur ini akan melakukan proses training dan pengujian dengan menggunakan data set image chest x-ray untuk mendeteksi keberadaan jenis penyakit covid-19. Untuk data set image penelitian ini didapatkan atau diperoleh dari <https://www.kaggle.com/code/ernestomaisuls/covid-19-x-ray-modified-xception/data>.

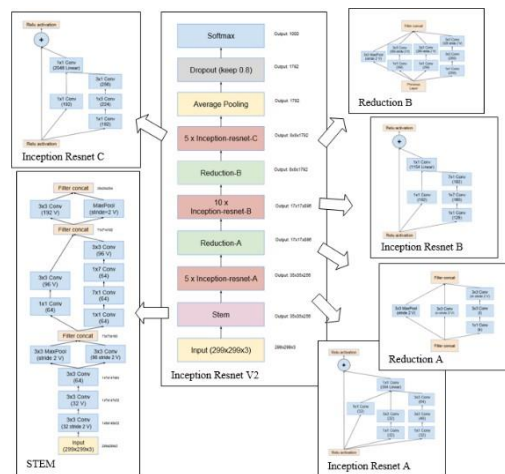




Gambar 8. Komparasi akurasi arsitektur CNN berdasarkan ILSVRC


## InceptionResNet-V2

Sebagai upaya pengembangan CNN, Szegedy (2014) memperkenalkan Inception dalam papernya yang berjudul “Going Deeper with Convolution”. Dimana Convolution ini merupakan tindakan ekstraksi image untuk mendapatkan model dalam bentuk matrik kernel. Pada proses ini dilakukan filterisasi yang bergeser dengan “stride value” tertentu pada suatu input image. Atau suatu proses untuk melihat nilai parameter yang menentukan berapa banyak jumlah pergeseran filter pada suatu input image. Selanjutnya hasil dari convolution menjadi input bagian fully connected untuk proses klasifikasi.



Gambar 12. Blok modul Inception Resnet V2



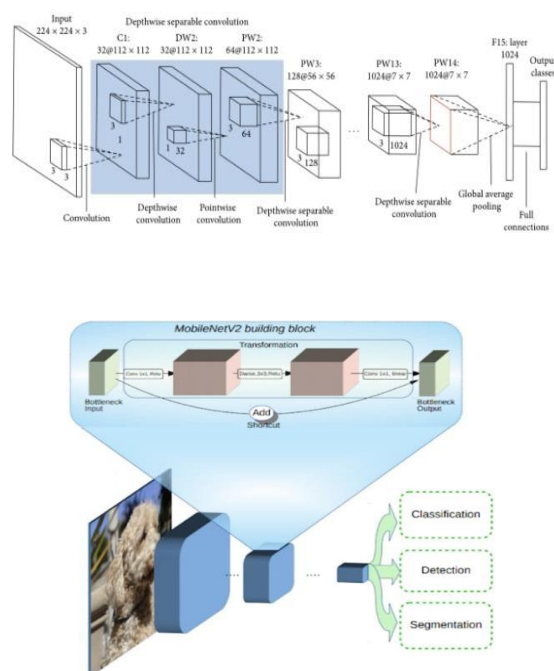


Gambar 13. Diagram keseluruhan Inception Resnet V2

Dengan menggunakan Arsitektur InceptionResNet-V2 ini dapat menghasilkan performa yang sangat baik dengan komputasi yang relatif rendah. Dan semakin banyak data yang akan kita olah maka akan semakin tinggi tingkat akurasi.

## MobileNet-V2

Penggunaan feature inverted residual blok dan bottleneck membedakan mobilenet vaersi 2 ini dengan mobilenet aslinya. Feature ini mampu menurunkan jumlah kalkulasi yang dilakukan mesin dibanding mobilenet asli. Dukungan mobilenet versi 2 untuk menerima image input lebih dari 32x32, memberikan kemampuan lebih baik untuk image berukuran besar. Karena mobilenet di rancang untuk apilkasi mobile, maka arsitektur ini harus mampu berjalan dengan kemampuan computer yang seminim mungkin namun tetap dapat memberikan tingkat akurasi yang tinggi.




Gambar 14. Arsitektur mobilenet (atas) dan block modul linear bottleneck (bawah)

## Preparasi Data Dan Tahap Penelitian


Penelitian ini menggunakan dataset input sebanyak 4000 image, terbagi menjadi 4 kelas, yaitu:

0 – Normal	1.000 image (25%)
1 – Viral Pneumonia	1.000 image (25%)
2 – Lung_Opacity	1.000 image (25%)
3 – Covid	1.000 image (25%)

Dari 1000 image data tiap kelas terbagi 80% (800 image) untuk data training dan 20% (200 image) untuk validasi data. (Gambar 15).

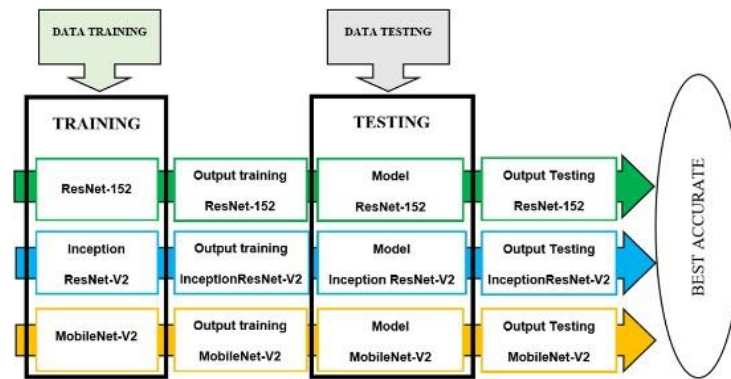


Gambar 15. Pie dan histogram dataset



Gambar 16. Dataset Image Chest XRay

Dataset input (data train dan validasi) dipergunakan sebagai data latih untuk 2 arsitektur CNN ini, hasil dari training berupa model yang dapat dipergunakan untuk mengklasifikasi image. Untuk memperoleh besar pengukuran akurasi maka dilakukan pengujian dengan menggunakan data testing sebanyak 4000 image (1000 image tiap kelas).



Gambar 17. Tahap penelitian

## HASIL DAN PEMBAHASAN


Hasil dari proses training dengan data input diperoleh nilai train accuracy, train loss, val accuracy dan val loss dari keempat arsitektur, sebagai berikut: (Tabel 1)

Tabel 1. Hasil Training

		InceptionResNet	MobileNet-V2
T R A I N	Loss	0.3769	0.3823
	Acc	0.9958	0.9942
V A L I D	Loss	0.52	0.4792
	Acc	0.9175	0.9388
Histo ry	Train Acc, Val Acc, Train Loss, Val Loss		
Grafik	Train Acc Valid Acc		
	Train Loss Valid Loss		

Dari table 1 terlihat prosentase untuk train dan valid accurate pada arsitektur CNN InceptionResNet-V2 adalah sangat bagus (>90%), namun untuk valid loss masih terlihat cukup besar (>40%) dan perlu peningkatan kembali agar nilainya menjadi lebih kecil. Sedangkan untuk train loss adalah < 40 %.





Gambar 18. Grafik Presisi & Accurate dari 2 arsitektur CNN

## KESIMPULAN

Hasil penelitian untuk memprediksi jenis penyakit covid dari data image Chest X Ray menggunakan 2 arsitektur CNN adalah sangat baik dengan nilai akurasi lebih dari 95%. Dan untuk Hasil arsitektur CNN InceptionResNet- V2 adalah dengan nilai akurasi 98% dan presisi untuk tiap kelasnya lebih dari 95% yaitu: Covid (99%), Lung\_Opacity (97%), Normal (99%), Viral\_Pneumonia (99%). Dalam masa pandemi COVID-19 yang semakin memburuk serta adanya varian baru dengan tingkat sebaran penularan yang lebih tinggi, maka penerapan teknologi intelegensi artifisial (AI) dalam dunia kedokteran (medis) adalah sangat diperlukan untuk membantu meringankan kerja para medis. Dengan mesin learning diagnosa Covid dapat dilaksanakan dengan tepat, cepat dan biaya yang sangat murah. Peralatan CT Scan tersedia hampir di semua rumah sakit tiap kota di Indonesia. Hal ini memudahkan pasien untuk memperoleh gambar chest x-ray. Hasil model dari penelitian ini dapat dipergunakan (embedding) dalam bentuk mobile internet atau dalam bentuk sistim yang berbasis web, sehingga setiap saat dan di manapun berada pasien dapat melakukan scanning dan mendapatkan hasil prediksi secara langsung (real time) dengan biaya murah, akurat dan cepat.

## DAFTAR PUSTAKA

- Worldometers, "Coronavirus Cases in India," Worldometers, 2021. [Online]. Available: <https://www.worldometers.info/coronavirus/country/india/>. WHO Indonesia, "Coronavirus Disease 2019 (COVID-19)," 2021.
- Ahmad Naufal, "Selain Hong Kong, Sejumlah Negara Ini Masih Melarang Masuk WNI," Kompas. com, 2021. (Online). Available:<https://www.kompas.com/tren/read/2021/06/25/103000965/selain-hong-kong-sejumlah-negara-ini-masih-melarang-masuk-wni?page=all>.

- B. Priyono, "Student Notes: Convolutional Neural Networks (CNN) Introduction," Indoml.com. [Online]. Available: <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>.
- Covid19.GO.id, "Data Sebaran," 2021. [Online]. Available: <https://COVID19.GO.id/>.
- G. Zeng, Y. He, Z. Yu, X. Yang, R. Yang, and L. Zhang, "Going Deeper with Convolutions," J. Chem. Technol. Biotechnol., vol. 91, no. 8, pp. 2322–2330, 2016.
- L. Alzubaidi et al., Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, vol. 8, no. 1. Springer International Publishing, 2021.
- L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Simulated Annealing Algorithm for Deep Learning," Procedia Comput. Sci., vol. 72, pp. 137–144, 2015.
- L. M. R. Rere, R. Dalam, and K. Baru, "Studi Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network," vol. 3, 2019.
- L. M. Rasdi Rere, M. I. Fanany, and A. M. Arymurthy, "Metaheuristic Algorithms for Convolution Neural Network," Comput. Intell. Neurosci., vol. 2016, 2016.
- M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MOBilenetV2: Inverted Residuals and Linear Bottlenecks," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., pp. 4510–4520, 2018.
- M. Längkvist, L. Karlsson, and A. Loutfi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning," Pattern Recognit. Lett., vol. 42, no. 1, pp. 11–24, 2014.
- N. Van Hieu and N. L. H. Hien, "Recognition of plant species using deep convolutional feature extraction," Int. J. Emerg. Technology, vol. no. 3, pp. 904 – 910, 2020.
- Sebastian Raschka, "Activation Functions for Artificial Neural Networks," github.io, 2020. [Online]. Available: [http://rasbt.github.io/mlxtend/user\\_guide/general\\_concepts/activation-functions/](http://rasbt.github.io/mlxtend/user_guide/general_concepts/activation-functions/).
- S. B. Karno, W. Hastomo, and I. S. K. Wardhana, "Prediksi Jangka Panjang Covid-19 Indonesia Menggunakan Deep Learning Long-Term," Semin. Nas. Teknol. Inf. dan Komun., pp. 483–490, 2020.
- S. Bianco, R. Cadene, L. Celona, and P. Napoletano, "Benchmark analysis of representative deep neural network architectures," IEEE Access, vol. 6, pp. 64270–64277, 2018.
- S.B. Smith, G.W. Ruhnke, C.H. Weiss, G.W. Waterer, R.G. Wunderink, Trends in pathogens among patients hospitalized for pneumonia from 1993 to 2011, JAMA Intern. Med. 174 (11) (2014) 1837–1839, doi:10.1001/JAMainternmed.2014.4344.

- V. Ayumi, L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Optimization of convolutional neural network using microcanonical annealing algorithm," 2016 Int. Conf. Adv. Comput. Sci. Inf. Syst. ICACSIS 2016, pp. 506–511, 2017.
- W. Hastomo and A. Satyo, "Kemampuan Long Short Term Memory Machine," vol. 4, no. September, pp. 229–236, 2020.