

## OPTIMASI CONVOLUTION NEURAL NETWORK UNTUK DETEKSI COVID-19

\***Widi Hastomo<sup>1</sup>, Adhitio Satyo Bayangkari Karno<sup>2</sup>, & Indra Bakti<sup>3</sup>**

<sup>1,3</sup>Teknologi Informasi, ITB Ahmad Dahlan Jakarta, Indonesia

<sup>2</sup>Sistem Informasi, Universitas Gunadarma, Indonesia

\*Widie.has@gmail.com

**Abstrak:** Optimasi Convolution Neural Network Untuk Deteksi Covid-19. Kondisi pandemi seperti sekarang ini diperlukan sebuah algoritma pembelajaran mesin untuk mendeteksi covid-19 secara otomatis berdasarkan pada gambar rontgen dada guna memudahkan dalam membantu pengambil keputusan. Penelitian ini ingin membandingkan arsitektur CNN AlexNet dan MobileNetV2 untuk mendeteksi (a) covid-19, (b) lung opacity, (c) normal, (d) viral pneumonia. Data himpunan rontgen dada yang digunakan sejumlah 4000 yang berasal dari kaggle.com, 0.8 data dibagi untuk pelatihan sedangkan 0.2 nya digunakan untuk pengujian. Optimizer yang digunakan yaitu keras SGD momentum, dengan nilai learning rate 0.005 dan momentum 0.9, serta epoch 50. Ukuran gambar untuk input yaitu 224x224 serta ukuran batch 32. Hasil optimasi dari kedua algoritma tersebut yaitu, MobileNetV2 lebih baik untuk mendeteksi covid-19 dengan nilai akurasi presisi mencapai 99%. Penelitian selanjutnya dapat membandingkan algoritma CNN yang lainnya serta data himpunan yang lebih banyak.

**Kata kunci:** CNN; AlexNet; MobileNetV2; Covid-19

**Abstract:** Convolution Neural Network Optimization for Covid-19 Detection. In the current pandemic conditions, a machine learning algorithm is needed to detect COVID-19 automatically based on chest X-ray images to make it easier to assist decision makers. Aim study be disposed for compare the architecture of CNN AlexNet and MobileNetV2 to detect (a) covid-19, (b) lung opacity, (c) normal, (d) viral pneumonia. The data set of chest X-rays used are 4000 from kaggle.com, 0.8 of the data is shared for training while 0.2 is used for testing. The optimizer used is hard SGD momentum, with a value of leaning rate 0.005 and momentum 0.9, and epoch 50. The image size for the input is 224x224 and the batch size is 32. The optimization results from the two algorithms are, MobileNetV2 is better for detecting covid-19 with an accuracy value The precision reaches 99%. Future research can compare other CNN algorithms and larger data sets.

**Keywords:** CNN; AlexNet; MobileNetV2; Covid-19

---

*History & License of Article Publication:*

*Received:* 30/11/2022    *Revision:* 16/12/2022    *Published:* 31/12/2022

---

DOI: <https://doi.org/10.37971/radial.v10i2.299>

---



This work is licensed under a [Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/).

---

## PENDAHULUAN

Novel coronavirus (Covid-19) telah menjadi pandemi selama lebih dari dua tahun terakhir, Hari ini, virus covid-19 telah menjelma masalah kesehatan masyarakat yang serius dalam seluruh dunia (Z. Zhang, Cui, and Zhu 2020). Menurut data statistik worldometers, jumlah yang terinfeksi diseluruh dunia mencapai 647.591.353 orang, total meninggal dunia mencapai 6.639.192 orang (Anon 2022). Karena infeksi virus yang tinggi, penting untuk mengontrol penyakit, termasuk diagnosis cepat dan karantina tepat waktu.

Dengan kecepatan penyebaran yang semakin eksponensial, upaya yang serius dilakukan guna menyelamatkan kesehatan masyarakat secara intensif dilakukan (Tedros Adhanom Ghebreyesus 2021). Pemerintah Indonesia telah melakukan upaya pencegahan penyebaran virus, dengan cara pembatasan sosial serta pemberian vaksin kepada seluruh masyarakat. Walaupun telah divaksin, namun protokol kesehatan tetap harus dijalankan.

Virus ini menyebabkan pneumonia pada pasien. Infeksi pneumonia di paru-paru membuat pasien sulit bernapas dan menyebabkan pasien meninggal saat virus menyebar. Menurut pedoman terbaru yang diterbitkan oleh Organisasi Kesehatan Dunia (WHO), *reverse transcription-polymerase chain reaction* (RT-PCR) ataupun gen urutan untuk pernapasan atau sampel darah harus memvalidasi diagnosis coronavirus sebagai indikator yang utama untuk rawat inap (Corman et al. 2020). Tapi butuh waktu lama menggunakan alat yang relevan untuk mendeteksi virus, selain waktu yang relatif lama yang diperlukan untuk diagnosis, serta juga kurang sensitif terhadap deteksi virus (Corman et al. 2020). Selain itu, penelitian sebelumnya telah menunjukkan bahwa sebagian besar dokter dan perawat telah terpapar Covid-19 selama pengambilan sampel salvia berdasarkan kit RT-PCR (Kauczor and Hellbach 2021). Jumlah alat ini juga terbatas dan membutuhkan biaya relatif mahal. Menurut informasi dari beberapa dokter dan perawat, diagnosis berdasarkan alat RT-PCR pada akhirnya tidak hemat biaya. Karena itu, diagnosis cepat Covid-19 diperlukan untuk mengobati dan mengendalikan penyakit (Esposito et al. 2020).

Rontgen dada (*image chest x-ray*) menjadi salah satu pilihan metode yang digunakan selama perawatan penyakit ini (Ai et al. 2020). *Computerized tomography* (CT) dan *Digital Radiography* (DR) atau sinar-X 2D standar termasuk di antara metode pencitraan dada. DR digunakan untuk memindai tubuh untuk diagnosis patah tulang, infeksi paru-paru, pneumonia dan tumor. CT adalah DR yang canggih yang dapat memberikan gambar organ yang lebih jelas, tulang, dan jaringan. Namun, CT *scan* tidak tersedia di semua rumah sakit dan biayanya tidak semurah DR. Karena keterbatasan alat, biasanya dokter menggunakan DR untuk langkah pertama diagnosis. Menggunakan DR lebih cepat, lebih mudah, lebih terjangkau daripada CT (Ai et al. 2020). Namun untuk mendiagnosa hasil dari DR, dokter menganalisis secara visual (manual) virus, infeksi, bakteri, karena jumlah pasien yang terindikasi virus banyak, menjadikan tenaga dokter terbatas. Konsistensi gambar dada *X-ray* memiliki kekurangan tertentu, seperti kontras rendah, tumpang tindih organ dan batas kabur, yang memiliki dampak signifikan pada identifikasi pneumonia rontgen dada (Wu et al. 2020).

Berdasarkan pada fakta yang disebutkan di atas, deteksi otomatis virus jenis (termasuk Covid-19) berdasarkan gambar dada telah memperoleh banyak perhatian dalam penelitian terbaru (Hastomo 2021; Hastomo, Satyo, et al. 2021; Hastomo and Bayangkari 2021; Ioannis, Apostolopoulos, and A 2020; Satyo et al. 2021; Tan and Le 2019; Tanvir, Md, and Shaikh 2020). Deteksi otomatis Covid-19 tidak hanya menyebabkan diagnosis cepat tetapi juga mengurangi beban kerja dokter dan berguna untuk perawatan tepat waktu dan pengurangan risiko kematian pasien. Baru-baru ini, berbagai metode komputasi berdasarkan *deep learning* telah dikembangkan untuk observasi dan analisis penemuan otomatis Covid -19 memanfaatkan gambar X-Ray. Deep Learning adalah perpaduan

metode untuk pembelajaran mesin, terutama ditujukan untuk mengekstraksi dan mengklasifikasikan secara otomatis gambar sementara aplikasinya banyak ditemui di bidang pengenalan citra medis, segmentasi, dan klasifikasi (Ayumi, V., Rere, L. R., Fanany, M. I., & Arymurthy 2017; Ayumi et al. 2017; Hastomo 2020; Hastomo, Karno, et al. 2021; Hastomo and Satyo 2019; Andrew G. Howard et al. 2017; Karno, A. S. B., & Hastomo 2020; Karno, Hastomo, and Wardhana 2020; Lei et al. 2020; Rasdi Rere, Fanany, and Arymurthy 2016; Rere, Fanany, and Arymurthy 2015).

Penelitian yang dilakukan oleh (Abbas, Asmaa, and Mohammed 2021) mengusulkan model new deep CNN yang didasarkan pada DeTraC gambar rontgen dada, Eksperimen secara ekstensif mencapai akurasi 95,12%, 97,91% sensitivitas, dan spesifisitas 91,87% untuk sistem ini. (Mohamed et al. 2020) mengusulkan generative adversarial network dengan deep neural network, Googlenet mencapai akurasi 80,6% untuk klasifikasi empat kelas. Alexnet memperoleh akurasi 85,2% dalam tiga skenario kelas, dan Googlenet mencapai akurasi 100% dalam dua skenario kelas. (Rahimzadeh et al. 2020) mengembangkan beberapa deep neural network untuk klasifikasi otomatis Covid-19. Model terlatih yang digunakan untuk sistem ini adalah Xception dan ResNet50-V2, Eksperimen ekstensif menunjukkan akurasi rata-rata 91,4% untuk semua kelas. (Oh et al. 2020) mengusulkan *patch-based* CNN dengan jumlah parameter relatif kecil yang bisa dilatih, Eksperimen ekstensif menunjukkan akurasi 88,9%, presisi 83,4%, perolehan 85,9%, dan skor f1 score 84,4%. (J. Zhang et al. 2020) mengusulkan new deep learning-based model (model deteksi anomali) berdasarkan gambar sinar-X dada, Eksperimen ekstensif menyajikan sensitivitas 96% dan spesifisitas 70,65% untuk sistem ini.

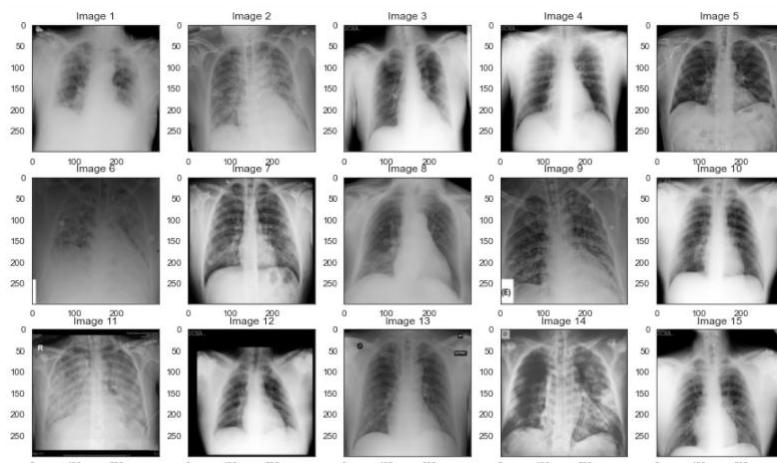
Ioannis et.,(Ioannis et al. 2020) memperkenalkan beberapa model terlatih CNN untuk deteksi Covid-19. Sistem menggunakan pembelajaran transfer untuk diagnosis dengan kumpulan data Covid-19 yang relatif kecil. Di antara model terlatih, MobileNetV2 mencapai akurasi 96,78%, sensitivitas 98,66%, dan spesifisitas 96,46% untuk dataset kedua. (Tanvir et al. 2020) mengusulkan new deep learning model bernama CovXNet menggunakan gambar rontgen dada untuk deteksi otomatis Covid-19 dan kasus pneumonia lainnya. Eksperimen ekstensif menyajikan akurasi 97,4% untuk Covid-19 dibandingkan kasus normal dan akurasi 90,2% untuk klasifikasi antara kasus Covid-19, normal, dan virus dan bakteri pneumonia. (Tsiknakis et al. 2020) mengembangkan deep learning-based model untuk mendiagnosis Covid-19 dari gambar rontgen dada. Model terlatih Inception-V3 diperkenalkan, Sistem ini menunjukkan akurasi 100%, sensitivitas 99%, dan spesifisitas 100% untuk Covid-19 versus klasifikasi umum biner pneumonia dan akurasi 76%, sensitivitas 93%, dan spesifisitas 87% untuk klasifikasi empat kelas. (Sethy and Prabira 2020) mengusulkan sistem di mana sembilan model terlatih yang berbeda mengekstraksi fitur dari gambar sinar-X dada. Sistem menggunakan SVM untuk mengklasifikasikan Covid-19 menggunakan fitur yang diekstrak. Di antara semua model, ResNet50 dianggap terbaik untuk ekstraksi fitur. Sistem memperoleh akurasi 95,33% dan skor F1 95,34% menggunakan ResNet50 dan SVM. (Horry et al. 2020) memperkenalkan skema di mana empat model pra-terlatih yang berbeda digunakan. Dataset tersebut berisi 115 sampel Covid-19, 322 kasus pneumonia, dan 60.361 sampel kasus sehat. Di antara

model, VGG16 dan VGG19 memiliki performa terbaik. VGG19 mencapai akurasi 81% untuk klasifikasi Covid-19 versus pneumonia.

Penelitian yang akan dilakukan ini akan mengambil manfaat dari dua arsitektur Convolution Neural Network MobileNet-V2 dan AlexNet guna mendeteksi Covid-19 bersumber pada gambar rontgen dada.

## METODE

Data himpunan yang digunakan untuk eksperimen ini bersumber dari kaggle.com (Corrochann 2020), kaggle merupakan komune ilmuwan data serta pembelajaran mesin terbesar di dunia, dimiliki Google, Inc. Jumlah data yang digunakan untuk eksperimen ini yaitu 4000 gambar rontgen dada, yang terpisah dalam 4 kelas; (a) normal, (b) Viral Pneumonia, (c) Lung Opacity, (d) covid. Setiap kelas memiliki 1000 gambar, dari jumlah tersebut 20% nya atau setara 200 gambar data digunakan untuk data validasi sedangkan 80% nya digunakan untuk data pelatihan. Gambar 1 merupakan himpunan data foto rontgen dada yang akan digunakan untuk eksperimen ini.



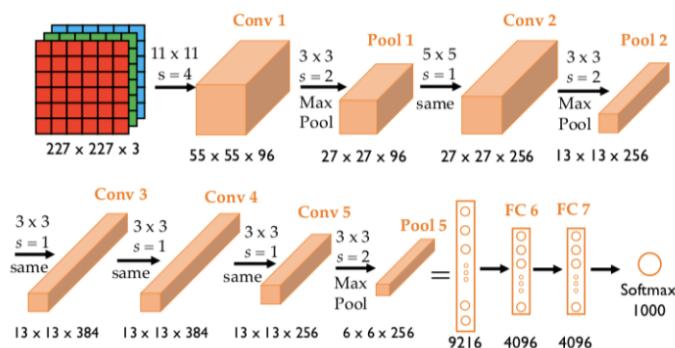
Gambar 1. Himpunan data foto rontgen dada

## CNN AlexNet

AlexNet mengacu pada jaringan saraf convolutional dengan delapan lapisan (ConvNet) yang merupakan pemenang *ILSVRC (ImageNet Large Scale Visual Recognition Competition)*, *Blackpool* untuk klasifikasi gambar, pada tahun 2012, terdiri dari 5 lapisan konvolusi, 3 lapisan yang terhubung penuh dengan *softmax* 1000 arah akhir, dengan total 60 juta parameter. Skala jaringan ini dianggap sangat mengesankan pada saat itu, dan sebagian dimungkinkan berkat implementasi konvolusi 2D yang sangat optimal pada GPU. Jaringan membutuhkan waktu 5-6 hari untuk dilatih pada 1,2 juta gambar menggunakan 2 GPU 3GB GTX 580, bahwa peningkatan dapat dilakukan hanya dengan GPU yang lebih cepat dan kumpulan data yang lebih besar. Pada saat itu, model diparalelkan sedemikian rupa sehingga GPU hanya berkomunikasi di lapisan tertentu, yang akibatnya menurunkan tingkat kesalahannya sebesar 1-2%. Fungsi aktivasi ReLU (bukan tanh) digunakan untuk mempercepat pembelajaran.

Regularisasi *dropout* digunakan untuk mengurangi *overfitting* di lapisan yang terhubung penuh. *Augmentasi* data digunakan untuk meningkatkan ukuran kumpulan data secara artifisial dan sebagai hasilnya mengurangi *overfitting*. Ini dilakukan baik melalui terjemahan gambar dan refleksi horizontal dengan mengekstrak *patch* secara acak dan refleksi horizontalnya dari gambar yang telah diubah ukurannya, atau mengubah intensitas saluran RGB dalam gambar pelatihan. Makalah ini melaporkan hasil, termasuk tingkat kesalahan top-1 dan top-5, pada dataset ILSVRC-2010 dan ILSVRC-2012.

Gambar dari *dataset* telah diubah ukurannya menjadi  $256 \times 256$ , gambar non-kuadrat dipangkas terlebih dahulu. Nilai RGB untuk setiap piksel dinormalisasi menggunakan rata-rata set pelatihan. Arsitektur model ditunjukkan pada gambar 2.



Gambar 2. Arsitektur AlexNet

Augmentasi data digunakan untuk memperbesar ukuran kumpulan data secara artifisial. Salah satu bentuk augmentasi data yang digunakan dalam model dilakukan dengan mengekstrak *patch*  $224 \times 224 \times 3$  secara acak dari  $256 \times 256$  gambar. Tambalan ini kemudian melewati 5 lapisan konvolusi dan 3 lapisan yang terhubung penuh. Risiko kesalahan ada dalam langkah ini dan dimensi tambalan harus  $227 \times 227 \times 3$ .

Lapisan konvolusi pertama: 96 kernel ukuran  $11 \times 11 \times 3$  dan langkah 4 piksel, diikuti oleh lapisan penyatuhan maks ukuran  $3 \times 3$  dan langkah 2. Dimensi *output* adalah  $55 \times 55 \times 96$  setelah Konv 1, dan  $27 \times 27 \times 96$  setelah Pool 1. Lapisan konvolusi ke-2: konvolusi yang sama dengan 256 kernel ukuran  $5 \times 5 \times 96$  dan langkah 1, diikuti oleh lapisan penyatuhan maks ukuran  $3 \times 3$  dan langkah 2. Dimensi *output* adalah  $27 \times 27 \times 256$  setelah Konv 2 ( $p=2$ ), dan  $13 \times 13 \times 256$  setelah Pool 2. Lapisan konvolusi ke-3: konvolusi yang sama dengan ukuran 384 kernel  $3 \times 3 \times 256$ , dan langkah 1, tidak ada penyatuhan. Dimensi keluaran adalah  $13 \times 13 \times 384$  setelah Konv 3 ( $p=1$ ).

Lapisan konvolusi ke-4: konvolusi yang sama lagi dengan 384 kernel berukuran  $3 \times 3 \times 384$ , dan langkah 1, tanpa penyatuhan. Dimensi keluaran adalah  $13 \times 13 \times 384$  setelah Konv 4 ( $p=1$ ). Lapisan konvolusi ke-5: konvolusi yang sama lagi dengan 256 kernel ukuran  $3 \times 3 \times 384$  dan langkah 1, diikuti oleh lapisan penyatuhan ukuran maksimal  $3 \times 3$  dan langkah 2. Dimensi *output* adalah  $13 \times 13 \times 256$  setelah Konv 5 ( $p=1$ ), dan  $6 \times 6 \times 256$  setelah Pool 5. Lapisan 6 dan 7 adalah lapisan yang terhubung penuh, masing-masing memiliki 4.096 *neuron* 8 dan juga lapisan terakhir adalah *softmax* 1.000 arah. Bentuk dan ukuran

aktivasi serta jumlah parameter untuk setiap lapisan ditabulasikan pada gambar 3. Jumlah total parameter dihitung menjadi 62.369.155.

	Activation shape	Activation size	# parameters
Input image	227 x 227 x 3	154587	0
Conv 1	55 x 55 x 96 (f=11 s = 4 p = 0)	290400	34944
Pool 1	27 x 27 x 96 (f=3 s = 2)	69984	0
Conv 2	27 x 27 x 256 (f=5 s = 1 p = 2)	186624	614,656
Pool 2	13 x 13 x 256 (f=3 s = 2)	43264	0
Conv 3	13 x 13 x 384 (f=3 s = 1 p = 1)	64896	885,120
Conv 4	13 x 13 x 384 (f=3 s = 1 p = 1)	64896	1,327,488
Conv 5	13 x 13 x 256 (f=3 s = 1 p = 1)	43264	884,992
Pool 5	6 x 6 x 256 (f=3 s = 2)	9216	0
FC 3	4096 x 1	4096	37,748,737
FC 4	4096 x 1	4096	16,777,217
Softmax	1000 x 1	1000	4096001

Gambar 3. Bentuk dan ukuran aktivasi dan jumlah parameter

Model dilatih menggunakan penurunan gradien stokastik dengan momentum pada *batch mini* misal pada ukuran 128. Nilai parameter momentum yang digunakan adalah 0,9 dan bobot peluruhan 0,005.

$$v_{i+1} := 0.9v_i - 0.005 \times \nabla w_i - \epsilon \times [\frac{\partial L}{\partial w}]D_i \quad (1)$$

$$w_i + 1 := w_i + v_{i+1} \quad (2)$$

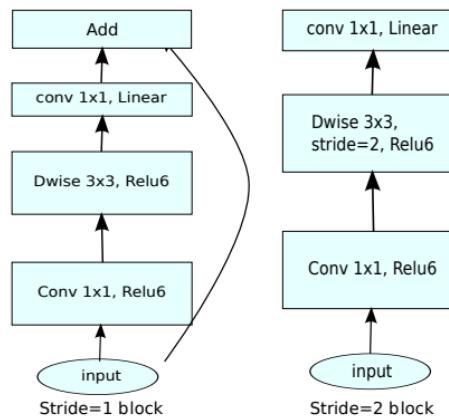
Di mana i adalah indeks iterasi, v adalah variabel momentum (kecepatan),  $\epsilon$  adalah kecepatan pembelajaran, yang sama untuk semua lapisan dan telah disesuaikan secara manual selama pelatihan berdasarkan bagaimana kesalahan validasi diperbaiki, mulai dari 0,01. Bobot w diinisialisasi dari distribusi Gaussian rata-rata nol dengan standar deviasi 0,01.  $[\frac{\partial L}{\partial w}]D_i$  adalah rata-rata pada batch ke-i dari turunan fungsi *loss* terhadap w yang dievaluasi pada wi. Bias diinisialisasi ke 1 di lapisan konvolusi ke-2, ke-4, dan ke-5 serta lapisan yang sepenuhnya terhubung untuk mempercepat tahap awal pembelajaran dengan memberikan masukan positif kepada ReLU. Bias di lapisan lain diinisialisasi ke 0.

## CNN MobileNetV2

Kemampuan untuk menjalankan jaringan yang lebih dalam pada perangkat seluler pribadi meningkatkan pengalaman pengguna, menawarkan akses kapan saja, di mana saja, dengan manfaat tambahan untuk keamanan, privasi, dan konsumsi energi. Saat aplikasi baru muncul dapat memungkinkan pemakai guna berinteraksi serta dunia nyata secara *real*.

*time*, begitu pula kebutuhan akan jaringan saraf yang lebih efisien. Ketersediaan MobileNetV2 untuk mendukung aplikasi *mobile vision* generasi berikutnya. MobileNetV2 adalah peningkatan yang signifikan atas MobileNetV1 dan mendorong keadaan seni untuk pengenalan *visual mobile* termasuk klasifikasi, deteksi objek dan segmentasi semantik. MobileNetV2 dirilis sebagai bagian dari TensorFlow-Slim Image Classification Library.

MobileNetV2 dibangun di atas ide-ide dari MobileNetV1 (A. G. Howard et al. 2017), menggunakan konvolusi yang dapat dipisahkan secara mendalam sebagai blok bangunan yang efisien. Namun, V2 memperkenalkan dua fitur baru ke arsitektur: 1) kemacetan linier antara lapisan, dan 2) koneksi pintasan antara kemacetan1. Struktur dasar ditunjukkan pada gambar 4.



Gambar 4. Arsitektur MobileNetV2

Intuisinya adalah kemacetan dapat mengkodekan masukan serta keluaran sebagai penghubung model, deskriptor pada piksel untuk menuju ke tingkat yang tinggi merupakan kemampuan pengubah konsep lapisan dalam. Terakhir, akurasi yang optimal serta pelatihan data yang lebih cepat merupakan koneksi residual secara tradisional. MobileNetV2 adalah ekstraktor fitur yang sangat efektif untuk deteksi dan segmentasi obyek. Misalnya, untuk deteksi saat dipasangkan dengan SSDLite yang diperkenalkan (Sandler et al. 2018), model ini sekitar 35% lebih cepat dengan akurasi yang sama dari MobileNetV1.

Tabel 1. Perbandingan MobileNetV1 dengan MobileNetV2

Model	Params	Multiply-Adds	mAP	Mobile CPU
MobileNetV1 + SSDLite	5.1M	1.3B	22.2%	270ms
<u>MobileNetV2 + SSDLite</u>	4.3M	0.8B	22.1%	200ms

Sumber: (Sandler et al. 2018)

Seperti yang telah kita lihat MobileNetV2 menyediakan model berorientasi seluler yang sangat efisien yang dapat digunakan sebagai dasar untuk banyak tugas pengenalan visual.

### Optimizer SGD Momentum

Momentum Nesterov adalah salah satu inovasi pertama yang meningkatkan kecepatan konvergensi algoritma optimasi. Momentum Nesterov adalah contoh teknik

yang menggunakan momentum. Teknik momentum memperkenalkan informasi dari langkah-langkah masa lalu ke dalam penentuan langkah saat ini. Dengan kata lain, penurunan dalam metode algoritma yang menggunakan teknik momentum tidak hanya bergantung pada satu penentuan algoritma saat ini, tetapi juga pada beberapa langkah yang telah diambil di masa lalu.

Momentum memiliki dua keuntungan. Salah satunya adalah membantu mengatasi salah satu masalah utama dengan SGD secara langsung: perangkap lokal minimal. Keuntungan lainnya adalah teknik momentum memungkinkan pengoptimal untuk belajar lebih cepat, khususnya dengan membuatnya lebih aman untuk memilih kecepatan belajar serta mengolah data yang besar.

### Metrik Evaluasi

Metrik yang digunakan untuk mengevaluasi metode yang diusulkan dalam eksperimen ini adalah , skor F1 dan AP (presisi rata-rata) adalah digunakan untuk mengevaluasi model yang dilatih oleh fungsi *lost*.

Rumus dinyatakan sebagai berikut.

$$P = \frac{TP}{TP+FP} \quad (3)$$

$$R = \frac{TP}{TP+FN} \quad (4)$$

$$F1 = \frac{2PR}{P+R} \quad (5)$$

Formula yang disebutkan di atas, P merupakan tingkat akurasi, R adalah tingkat *recall*, TP adalah jumlah sampel positif benar, FP adalah jumlah sampel positif palsu dan FN adalah jumlah sampel negatif palsu.

### Lingkungan Operasi Eksperimen

Lingkungan perangkat keras eksperimen ditunjukkan pada Tabel 2. Atas dasar ini, lingkungan perangkat lunak dibangun sebagai berikut: Windows 2010, bahasa Python 3.9, dengan editor Jupyter Notebook. Kerangka kerja ini menggunakan TensorFlow dan Keras.

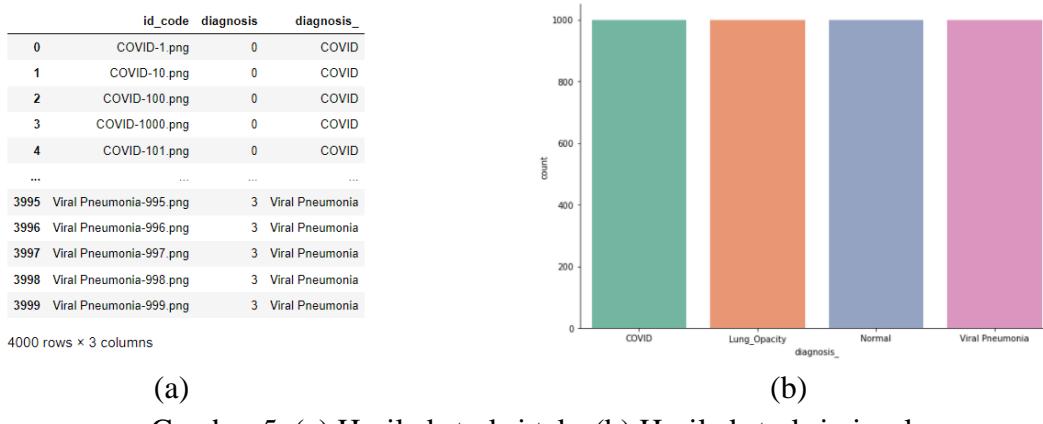
Tabel 2. Lingkungan operasi eksperimen

Perangkat Keras	Model	Jumlah
Main board	Asus Prime H510M-K	1
Memory	Klevv Neo N400 240 GB	1
CPU	Intel Core i5 10400F	1
Graphic card	ASUS Geforce GTX 1650 4GB	1
Hard disk	Seagate 1TB	1
Solid-state drives	Klevv Neo N400 240 GB	1

Sumber: Penulis 2022

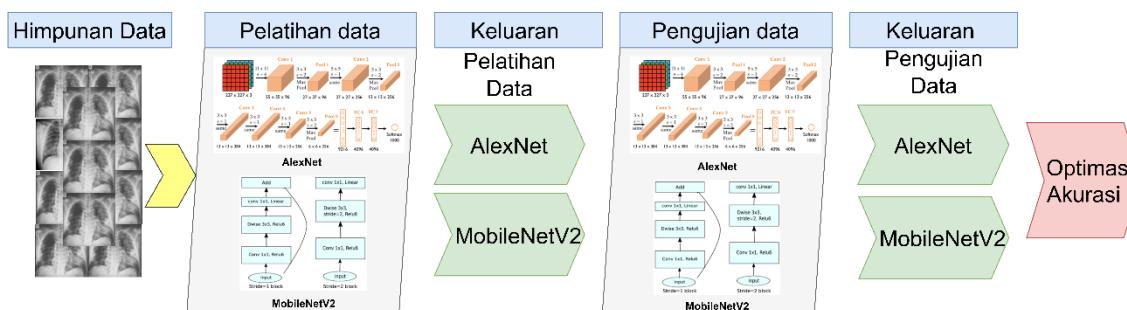
## Persiapan Himpunan Data

Data himpunan yang akan digunakan dalam eksperimen ini berjumlah 4.000 gambar rontgen data, dibagi menjadi 4 kategori; (a) covid, (b) lung opacity, (c) normal, (d) viral pneumonia. Ekstraksi hasil pembagian data himpunan terlihat pada gambar 5a terdapat 4.000 baris dan 3 kolom serta gambar 5b dalam bentuk visual grafik.



Gambar 5. (a) Hasil ekstraksi teks (b) Hasil ekstraksi visual

Optimasi akurasi dalam eksperimen ini dibandingkan antara arsitektur AlexNet dengan MobileNetV2. Proses eksperimen diawali dengan ekstraksi data himpunan, dilanjutkan dengan pelatihan data gambar yang berukuran 224x224 dengan ukuran batch 32. Data augmentasi digunakan untuk meningkatkan generalisasi dari model yang mungkin *overfitting*. Dengan menghasilkan data pelatihan tambahan dan memaparkan model ke versi data yang berbeda dalam kelas yang sama, proses pelatihan menjadi lebih kuat dan dengan demikian lebih mungkin untuk menggeneralisasi model yang dihasilkan. Hasil dari keluaran data pelatihan digunakan untuk iterasi pengujian data. Optimasi menggunakan SGD momentum dalam mencari hasil yang terbaik antara 2 algoritma tersebut. Alur eksperimen terlihat pada gambar 6.



Gambar 6. Alur eksperimen

## HASIL DAN PEMBAHASAN Hasil Penelitian

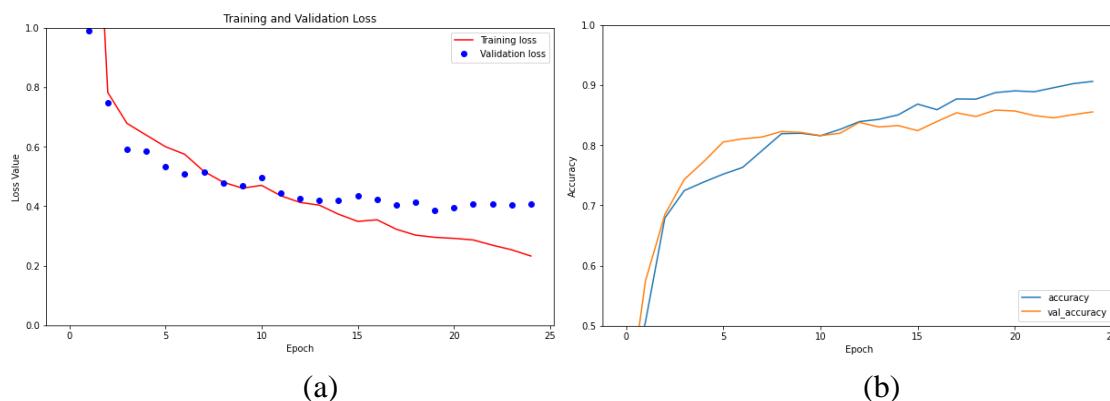
Perbandingan pelatihan data dari hasil eksperimen menggunakan arsitektur AlexNet dengan MobileNetV2 terlihat pada tabel 3. Nilai akurasi pelatihan dan validitas dengan

arsitektur MobileNetV2 lebih tinggi dibandingkan dengan AlexNet, mencapai 0.938. untuk nilai akurasi pelatihan MobileNetv2 mencapai 0.994

Tabel 3. Perbandingan Hasil Pelatihan

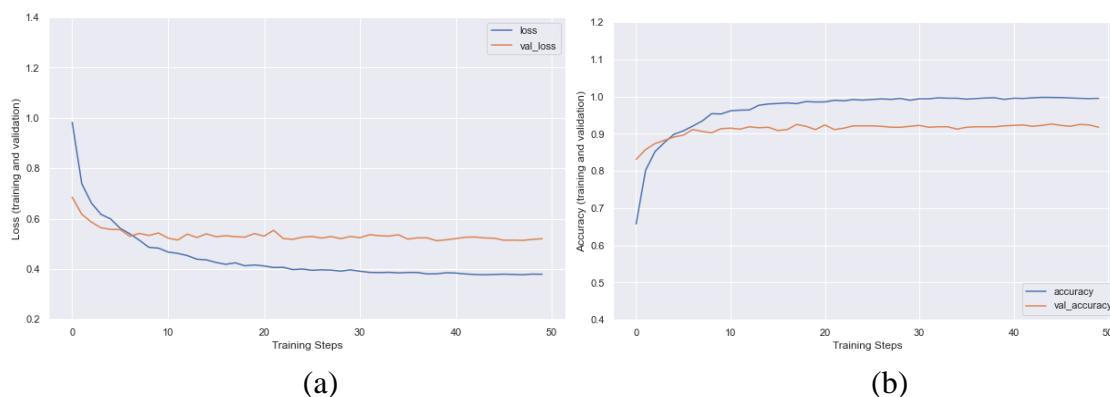
	Kategori	AlexNet	MobileNet-V2	Rerata
<b>Pelatihan</b>	<i>Loss</i>	0.223	0.382	0.3025
	Akurasi	0.911	0.994	0.9525
<b>Validitas</b>	<i>Loss</i>	0.407	0.479	0.4430
	Akurasi	0.855	0.938	0.8965

Sumber: Penulis 2022



Gambar 7. (a) *Loss* pelatihan dan validasi (b) Akurasi pelatihan dan validasi

Gambar 7 merupakan hasil dari eksperimen dengan arsitektur AlexNet dalam bentuk visual grafik, dengan akurasi validasi mencapai 0.8553. sedangkan akurasi dalam data latih mencapai 0.9119 termasuk dalam kategori baik.

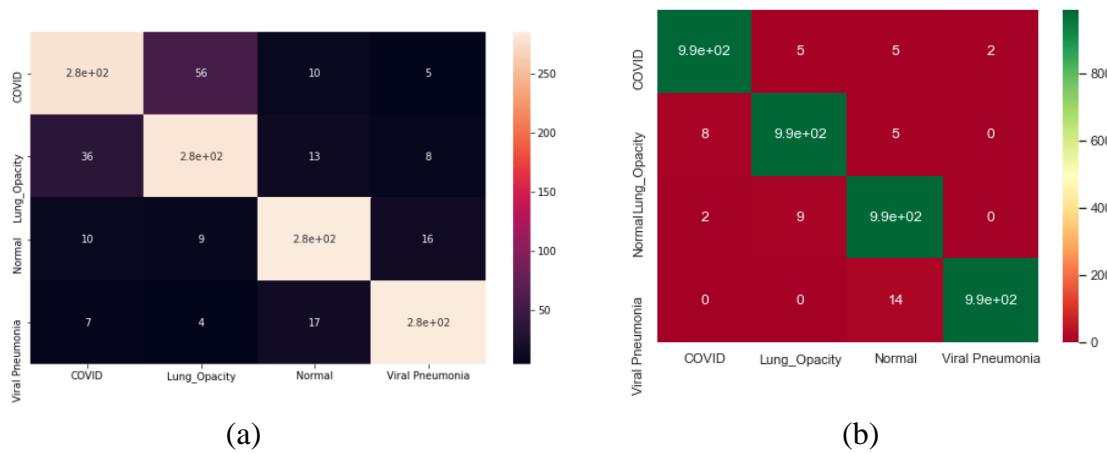


Gambar 8. (a) *Loss* pelatihan dan validasi (b) Akurasi pelatihan dan validasi

Hasil dari eksperimen MobileNetV2 untuk pelatihan himpunan data terlihat secara visual pada gambar 8. Capaian akurasi pelatihan dan validasi mencapai 0.9388, sedangkan nilai dari *loss* pelatihan dan validasi yaitu 0.9942, hasil ini termasuk dalam kategori sangat baik mendekati nilai 1.

Pustaka matplotlib.axes digunakan dalam eksperimen ini untuk membuat visual dari *confusion matrik* yang merupakan ringkasan hasil prediksi pada masalah klasifikasi.

Jumlah prediksi yang benar dan salah dirangkum dengan nilai hitungan dan dipecah oleh masing-masing kelas. Hasil dari visual grafik *confusion matrix* terlihat pada gambar 9.



Gambar 9. (a) Hasil Uji *Confussion Matric* AlexNet (b) Hasil Uji *Confussion Matric* MobileNetV2

### Pembahasan Hasil Penelitian

Hasil dari *confusion matrix* dapat diringkas pada tabel 4, merupakan perbandingan hasil pengujian dari kedua arsitektur AlexNet dan MobileNetV2 pada epoch 50.

Tabel 4. Perbandingan Hasil Presisi Pengujian

	Kategori	AlexNet	MobileNetV2
Presisi	Covid	0.84	0.99
	Lung Opacity	0.80	0.99
	Normal	0.88	0.98
	Viral Pneumonia	0.91	0.99
	<b>Akurasi</b>	0.86	<b>0.99</b>

Sumber: Penulis 2022

Eksperimen menggunakan algoritma AlexNet pada hasil pengujian presisi akurasi yaitu, kategori covid dengan nilai 0.84, lung opacity 0.80, normal 0.88, sedangkan viral pneumonia 0.91 dengan akurasi presisi mencapai 0.86. Sedangkan dari hasil arsitektur MobileNetV2 hasil presisi pengujian yaitu, covid 0.99, lung opacity 0.99, normal 0.98 serta viral pneumonia 0.99 dengan akurasi presisi mencapai 0.99, hal ini termasuk kategori sangat baik. Dapat disimpulkan bahwa optimasi dari 2 arsitektur ini, model MobileNetV2 mendapatkan nilai presisi lebih baik.

### KESIMPULAN

Kesimpulan dari eksperimen ini yaitu, arsitektur AlexNet dan MobileNetV2 dapat digunakan untuk mendeteksi; (a) covid-19, (b) lung opacity, (c) normal, (d) viral pneumonia berdasarkan pada gambar *rontgen* dada yang berjumlah 4000. Dari 4 kategori tersebut, hasil akurasi pengujian menggunakan arsitektur MobileNetV2 untuk deteksi

covid-19, lung opacity serta viral pneumonia mendapatkan nilai paling tinggi mencapai 99% hal ini dalam kategori sangat baik, mendekati nilai 1. Sedangkan hasil deteksi dengan kategori normal dengan nilai 98%. Hasil optimasi dari eksperimen ini dapat disimpulkan sebagai berikut; (a) akurasi presisi arsitektur MobileNetV2 mencapai 99%, (b) akurasi presisi arsitektur AlexNet mencapai 86%.

Arsitektur MobileNetV2 dapat menjadi pilihan sebagai alat pengambil keputusan untuk mendeteksi virus covid-19 dimasa pandemi. Hasil dari model ini dapat di embed pada website, untuk memudahkan petugas klinis (radiologi) dalam menentukan penyakit yang diderita oleh pasien. Website tersebut dapat di operasikan menggunakan *personal computer, smart phone* dan alat lainnya selama terhubung dengan jaringan internet. Biaya *rontgen* dada (*x-ray*) relatif lebih murah dibandingkan dengan biaya PCR, hasil *rontgen* dada dijadikan *input* untuk proses dalam mendeteksi pasien.

Eksperimen ini masih terbatas pada 2 arsitektur CNN, penelitian selanjutnya dapat mencoba membandingkan arsitekur CNN yang lainnya. Dapat menggunakan optimizer selain SGD momentum, serta himpunan data yang lain dapat diuji coba untuk penelitian selanjutnya.

## DAFTAR PUSTAKA

- Abbas, Abdelsamea Asmaa, and M. Mohammed. 2021. “Classification of COVID-19 in Chest X-Ray Images Using DeTraC Deep Convolutional Neural Network.” 854–64.
- Ai, T., Z. Yang, H. Hou, C. Zhan, C. Chen, ... & Lv, W., and L. Xia. 2020. *Correlation of Chest CT and RT-PCR Testing for Coronavirus Disease 2019 (COVID-19) in China*.
- Anon. 2022. “Covid-19 Coronavirus Pandemic.” Retrieved November 30, 2022 (<https://www.worldometers.info/coronavirus/>).
- Ayumi, V., Rere, L. R., Fanany, M. I., & Arymurthy, A. M. 2017. “Random Adjustment-Based Chaotic Metaheuristic Algorithms For Image Contrast Enhancement.” *Jurnal Ilmu Komputer Dan Informasi* 2(1):1–10. doi: <http://dx.doi.org/10.21609/jiki.v10i2.375>.
- Ayumi, Vina, L. M. Rasd. Rere, Mohamad Ivan Fanany, and Aniati Murni Arymurthy. 2017. “Optimization of Convolutional Neural Network Using Microcanonical Annealing Algorithm.” *2016 International Conference on Advanced Computer Science and Information Systems, ICACSIS 2016* 506–11. doi: [10.1109/ICACSIS.2016.7872787](https://doi.org/10.1109/ICACSIS.2016.7872787).
- Corman, Victor M., Olfert Landt, Marco Kaiser, Richard Molenkamp, Adam Meijer, Daniel K. W. Chu, Tobias Bleicker, Sebastian Brünink, Julia Schneider, Marie Luisa Schmidt, Daphne G. J. C. Mulders, Bart L. Haagmans, Bas Van Der Veer, Sharon Van Den Brink, Lisa Wijsman, Gabriel Goderski, Jean Louis Romette, Joanna Ellis, Maria Zambon, Malik Peiris, Herman Goossens, Chantal Reusken, Marion P. G. Koopmans, and Christian Drosten. 2020. “Detection of 2019 Novel Coronavirus (2019-NCoV) by Real-Time RT-PCR.” *Eurosurveillance* 25(3). doi: [10.2807/1560-7917.ES.2020.25.3.2000045](https://doi.org/10.2807/1560-7917.ES.2020.25.3.2000045).
- Corrochann. 2020. “COVID-19 Chest X-Ray Images.” *Kaggle.Com*. Retrieved (<https://www.kaggle.com/datasets?search=chest-xray+>).
- Esposito, Antonio, Anna Palmisano, Giulia Maria Scotti, Marco J. Morelli, Davide Vignale, Francesco de Cobelli, Giovanni Tonon, and Carlo Tacchetti. 2020. “Why

- Is Chest CT Important for Early Diagnosis of COVID-19? Prevalence Matters.” *MedRxiv*. doi: 10.1101/2020.03.30.20047985.
- Hastomo, W. 2020. “Gesture Recognition For Pencak Silat Tapak Suci Real-Time Animation.” *Journal of Computer Science and Information* 2(13):91–102. doi: http://dx.doi.org/10.21609/jiki:v13i2.855.
- Hastomo, Widi. 2021. “Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak.” 5(Gambar 1).
- Hastomo, Widi, and Satyo Bayangkari. 2021. “Diagnosa Covid-19 Chest X-Ray Dengan Convolution Neural Network Arsitektur Resnet-152.” 2(1):26–33.
- Hastomo, Widi, Adhitio Satyo Bayangkari Karno, Nawang Kalbuana, Ervina Nisfiani, and Lussiana ETP. 2021. “Optimasi Deep Learning Untuk Prediksi Saham Di Masa Pandemi Covid-19.” *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)* 7(2):133–40.
- Hastomo, Widi, and Adhitio Satyo. 2019. “Long Short Term Memory Machine Learning Untuk Memprediksi Akurasi Nilai Tukar IDR Terhadap USD.” 3.
- Hastomo, Widi, Adhitio Satyo, Bayangkari Karno, and Nawang Kalbuana. 2021. “Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia.” doi: 10.1088/1742-6596/1933/1/012050.
- Horry, Michael J., Subrata Chakraborty, Manoranjan Paul, Anwaar Ulhaq, and Biswajeet Pradhan. 2020. “X-Ray Image Based COVID-19 Detection Using Pre-Trained Deep Learning Models.”
- Howard, A. G., M. Zhu, B. Chen, D. Kalenichenko, W. Wang, ... & Weyand, T., and H. Adam. 2017. “Mobilenets: Efficient Convolutional Neural Networks for Mobile Vision Applications.” *ArXiv Preprint ArXiv*.
- Howard, Andrew G., Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, and Hartwig Adam. 2017. “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.”
- Ioannis, D., Tzani Apostolopoulos, and Mpesiana A. 2020. “Covid- 19: Automatic Detection from X- ray Images Utilizing Transfer Learning with Convolutional Neural Networks.”
- Karno, A. S. B., & Hastomo, W. 2020. “Optimalisasi Data Terbatas Prediksi Jangka Panjang Covid-19 Dengan Kombinasi LSTM Dan GRU.” *Prosiding SeNTIK* 4(September):181–91.
- Karno, Adhitio Satyo Bayangkari, Widi Hastomo, and Indra Sari Kusuma Wardhana. 2020. “Prediksi Jangka Panjang Covid-19 Indonesia Menggunakan Deep Learning Long-Term.” *Seminar Nasional Teknologi Informasi Dan Komunikasi* 483–90.
- Kauczor, U., and K. Hellbach. 2021. “COVID-19 Pneumonia and Its Lookalikes : How Radiologists Perform in Differentiating Atypical Pneumonias.” 144(June). doi: 10.1016/j.ejrad.2021.110002.
- Lei, Pinggui, Zhaoshu Huang, Guoli Liu, Pingxian Wang, Wen Song, Jujiang Mao, Guiquan Shen, Shi Zhou, Wei Qian, and Jun Jiao. 2020. “Clinical and Computed Tomographic (CT) Images Characteristics in the Patients with COVID-19 Infection: What Should Radiologists Need to Know?” *Journal of X-Ray Science and Technology* 28(3):369–81. doi: 10.3233/XST-200670.
- Mohamed, Loey, Smarandache Florentin, Eldeen Nour, and M. Khalifa. 2020. “Within the Lack of Chest COVID-19 X-Ray Dataset: A Novel Detection Model Based on GAN and Deep Transfer Learning.”
- Oh, Park Yujin, Ye Sangjoon, and Chul Jong. 2020. “Deep Learning COVID-19 Features on CXR Using Limited Training Data Sets.” *IEEE Transactions on Affective Computing* 1–13.

- Rahimzadeh, Mohammad, Attar, and Abolfazl. 2020. "Informatics in Medicine Unlocked A Modified Deep Convolutional Neural Network for Detecting COVID-19 and Pneumonia from Chest X-Ray Images Based on the Concatenation of Xception and ResNet50V2." *Informatics in Medicine Unlocked* 19:100360. doi: 10.1016/j imu.2020.100360.
- Rasdi Rere, L. M., Mohamad Ivan Fanany, and Aniati Murni Arymurthy. 2016. "Metaheuristic Algorithms for Convolution Neural Network." *Computational Intelligence and Neuroscience* 2016. doi: 10.1155/2016/1537325.
- Rere, L. M. Rasd., Mohamad Ivan Fanany, and Aniati Murni Arymurthy. 2015. "Simulated Annealing Algorithm for Deep Learning." *Procedia Computer Science* 72:137–44. doi: 10.1016/j.procs.2015.12.114.
- Sandler, Mark, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, and Liang Chieh Chen. 2018. "MobileNetV2: Inverted Residuals and Linear Bottlenecks." *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* 4510–20. doi: 10.1109/CVPR.2018.00474.
- Satyo, Adhitio, Bayangkari Karno, Widi Hastomo, Yasin Efendi, and Ruri Irawati. 2021. "Arsitektur Alexnet Convolution Neural Network ( CNN ) Untuk Mendeteksi Covid-19 Image Chest-Xray." 482–85.
- Sethy, and Kumar Prabira. 2020. "Detection of Coronavirus Disease ( COVID-19 ) Based on Deep Features and Support Vector Machine." (April).
- Sik-Ho Tsang. 2019. "Review: MobileNetV2 — Light Weight Model (Image Classification)." *Towards Data Science*. Retrieved (<https://towardsdatascience.com/review-mobilenetv2-light-weight-model-image-classification-8febb490e61c>).
- Tan, Mingxing, and Quoc V. Le. 2019. "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks." *36th International Conference on Machine Learning, ICML 2019* 2019-June:10691–700.
- Tanvir, Mahmud, Awsafur Rahman Md, and Anowarul Fattah Shaikh. 2020. "CovXNet: A Multi-Dilation Convolutional Neural Network for Automatic COVID-19 and Other Pneumonia Detection from Chest X-Ray Images with Transferable Multi-Receptive Feature Optimization." *Computers in Biology and Medicine* (January).
- Tedros Adhanom Ghebreyesus. 2021. *The Pandemic Is a Once-in-a-Century Health Crisis, the Effects of Which Will Be Felt for Decades to Come*. WHO.
- Tsiknakis, Nikos, Eleftherios Trivizakis, Evangelia E. Vassalou, Georgios Z. Papadakis, Demetrios A. Spandidos, and Aristidis Tsatsakis. 2020. "Interpretable Artificial Intelligence Framework for COVID - 19 Screening on Chest X - Rays." *Experimental and Therapeutic Medicine* 727–35. doi: 10.3892/etm.2020.8797.
- Wu, H., P. Xie, H. Zhang, & Li, D., and M. Cheng. 2020. "Predict Pneumonia with Chest X-Ray Images Based on Convolutional Deep Neural Learning Networks." *Journal of Intelligent & Fuzzy Systems* 39(3):2893–2907.
- Zhang, Jianpeng, Yutong Xie, Yi Li, Chunhua Shen, and Yong Xia. 2020. "COVID-19 Screening on Chest X-Ray Images Using Deep Learning Based Anomaly Detection." *ArXiv*.
- Zhang, Ziwei, Peng Cui, and Wenwu Zhu. 2020. "Deep Learning on Graphs: A Survey." *IEEE Transactions on Knowledge and Data Engineering* 14(8):1–1. doi: 10.1109/TKDE.2020.2981333.

## UCAPAN TERIMA KASIH

Dukungan dari LP3M ITB Ahmad dahlan sangat kami hargai, kami mengucapkan terimakasih, penelitian ini dapat berjalan dengan lancar.