

## Deteksi Citra X-Ray Paru-Paru Terinfeksi COVID-19 dengan Algoritma CNN Berbasis Aplikasi Web

Supri Bin Hj Amir <sup>1)</sup>, Sitti Nur Azizah Fitriani Akbar <sup>2)</sup>, Hendra <sup>3)</sup>,  
Andi Muhammad Anwar <sup>4)</sup>, Sulfayanti <sup>5)</sup>

<sup>1) 2) 3) 4)</sup> Sistem Informasi, FMIPA, Universitas Hasanuddin

Jl Perintis Kemerdekaan KM 10 Tamalanrea, Makassar, 90245

<sup>5)</sup> Teknik Informatika, Fakultas Teknik, Universitas Sulawesi Barat

E-Mail : [supriamir@unhas.ac.id](mailto:supriamir@unhas.ac.id) <sup>1)</sup>; [cicaazizahfit@unhas.ac.id](mailto:cicaazizahfit@unhas.ac.id) <sup>2)</sup>; [hendra@unhas.ac.id](mailto:hendra@unhas.ac.id) <sup>3)</sup>;  
[a.muhammadanwar@unhas.ac.id](mailto:a.muhammadanwar@unhas.ac.id) <sup>4)</sup>; [sulfayanti@unsulbar.ac.id](mailto:sulfayanti@unsulbar.ac.id) <sup>5)</sup>;

### ABSTRAK

Pada penelitian ini menggunakan algoritma *Convolutional Neural Network (CNN)* untuk mendeteksi COVID-19 berdasarkan citra X-ray Paru-paru. Arsitektur CNN yang digunakan adalah *EfficientNetB7* dan *Resnet152V2* dengan memanfaatkan teknik *Transfer Learning*. Penelitian ini berfokus pada membandingkan kinerja kedua model arsitektur dalam mengklasifikasikan citra X-ray Paru-paru terinfeksi COVID-19. Selanjutnya mengimplementasikan model CNN tersebut ke aplikasi deteksi Citra X-ray paru-paru berbasis web. Dari hasil evaluasi kedua model tersebut disimpulkan bahwa *Resnet152-V2* mencapai kinerja lebih baik dibanding arsitektur CNN *EfficientNetB7* dengan akurasi 97% sedangkan *EfficientNetB7* dengan akurasi 95%.

Kata Kunci – COVID-19, CNN, EfficientNetB7, Resnet152-V2, Web Aplikasi

### 1. PENDAHULUAN

Virus Corona atau *Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2)* merupakan virus yang dapat mengganggu sistem respirasi manusia. Virus Corona menyebabkan munculnya penyakit COVID-19 yang saat ini mewabah di seluruh dunia. *Reverse Transcription Polymerase Chain Reaction (RT-PCR)* digunakan untuk mendiagnosis COVID-19 dengan mengekstraksi 2 gen SARS-CoV-2. Uji yang dapat digunakan adalah dari sampel berupa swab tenggorokan. Swab merupakan bentuk tes yang marak untuk mendiagnosis virus corona. Namun, diagnosisnya memakan waktu yang cukup lama hingga beberapa hari untuk mendeteksi adanya COVID-19 pada tubuh pasien (Ahuja et al. 2021).

Dibandingkan dengan RT-PCR, pencitraan x-ray di paru-paru akan jauh lebih cepat untuk mendeteksi dan mengklasifikasikan pasien COVID-19. Namun, klasifikasi COVID-19 dengan x-ray tentunya membutuhkan ahli radiologi dengan waktu yang cukup lama, sehingga sangat darurat ketika infeksi COVID-19 menjalar dengan cepat. Oleh karena itu, analisis citra x-ray dengan metode deep learning sangat diperlukan untuk menghemat waktu para tenaga kesehatan dan menyelamatkan pasien dengan sigap (Singh et al. 2020).

Penelitian mengenai klasifikasi citra paru-paru terinfeksi COVID-19 dengan *Convolutional Neural Network (CNN)* berkembang dengan pesat. Pada penelitian ini, model arsitektur CNN yang digunakan adalah *EfficientNetB7* dan *Resnet152V2*. Fokus dari penelitian ini adalah membandingkan kinerja kedua arsitektur tersebut dalam mengklasifikasikan citra x-ray paru-paru terinfeksi COVID-19 maupun paru-paru normal dengan menganalisis akurasi, presisi, sensitivitas. Penelitian ini diharapkan mampu menunjukkan arsitektur CNN terbaik di antara keduanya dalam mengklasifikasikan dataset citra X-Ray Paru-paru. Model yang didapatkan pada tahap

training dan testing akan disimpan dalam format HDF5 dan selanjutnya digunakan untuk membangun aplikasi deteksi X-Ray Paru-paru berbasis Web. Manfaat penggunaan aplikasi berbasis web yang dirancang ini dapat mendeteksi hasil X-Ray Paru-paru terinfeksi COVID-19 dengan lebih cepat dan lebih murah dari segi biaya.

### 2. TINJAUAN PUSTAKA

#### A. *Coronavirus Disease 2019 (COVID-19)*

*Coronavirus Disease 2019 (COVID-19)* adalah penyakit menular yang disebabkan oleh jenis virus corona yang baru ditemukan di Wuhan pada tahun 2019 lalu, yaitu *Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2)*. Gejala-gejala paling umum yang mengindikasikan penyakit COVID-19 yaitu demam, batuk kering, kelelahan. Adapun gejala lainnya yang biasanya dialami oleh beberapa pasien yaitu rasa nyeri, hidung tersumbat, sakit kepala, konjungtivitis, sakit tenggorokan, diare, kehilangan indera perasa atau penciuman, ruam kemerahan pada kulit, dan perubahan warna jari tangan atau kaki (WHO 2020).

COVID-19 ditularkan dari droplet ketika seseorang dengan virus batuk, bersin, atau berbicara. Karena beratnya pandemi, memang diperlukan deteksi COVID-19 yang cepat dan hemat biaya. Untuk mendeteksi COVID-19, *Reverse-Transcriptase Polymerase Chain Reaction (RT-PCR)* adalah tes diagnostik standar yang dianggap sebagai tes yang memakan waktu. Namun, menggunakan pencitraan medis dengan X-Ray paru-paru dapat memainkan peran penting dalam diagnosis COVID-19 (Zhu et al. 2020).

#### B. *Deep Learning*

Berbeda dengan kebanyakan metode pembelajaran konvensional, yang dianggap menggunakan struktur arsitektur pembelajaran yang

dangkal, *Deep Learning* mengacu pada teknik Machine Learning yang menggunakan *Supervised* maupun *Unsupervised Learning* untuk secara otomatis mempelajari representasi hierarkis pada arsitektur yang dalam untuk klasifikasi (Mishra and Gupta 2017).

*Deep Learning* merupakan salah satu bidang dalam *Machine Learning* yang berarti pembelajaran mendalam. *Deep Learning* berkaitan dengan algoritma yang terinspirasi oleh struktur dan fungsi otak yang disebut jaringan saraf tiruan. *Deep Learning* membuat model komputasi yang terdiri dari beberapa lapisan pemrosesan yang sangat mendalam. Tujuannya untuk mempelajari representasi data dengan berbagai tingkat abstraksi.

Definisi teknis *Deep Learning* adalah penggunaan jaringan saraf dengan lebih dari satu atau dua lapisan. Lapisan jaringan saraf biasanya terdiri dari transformasi input parametrik dan non-linier. Penumpukan transformasi ini membentuk struktur data statistik yang mampu memetakan input berdimensi tinggi ke output. Pemetaan ini dilakukan dengan mengoptimalkan parameter. Penurunan gradien adalah alat pilihan untuk pengoptimalan ini. Penurunan gradien bekerja dengan mengambil turunan parsial dari loss function sehubungan dengan masing-masing parameter, dan memperbaiki parameter untuk meminimalkan *loss function*.

*Deep Learning* memiliki istilah “*Deep*” karena mengacu pada penumpukan beberapa lapisan. Sedangkan, “*Learning*” merujuk pada pengoptimalan parameter melalui pembelajaran. Model *Deep Learning* yang canggih biasanya berisi antara 100 juta hingga 10 miliar parameter dan 50–200 lapisan. Dua model terbesar yang dilaporkan secara publik terdiri dari 175 miliar parameter. Memperbesar ukuran model *Deep Learning* ini telah dilakukan dengan sangat cepat dalam beberapa tahun terakhir (Shorten, Khoshgoftaar, and Furht 2021).

### C. Convolutional Neural Network (CNN)

*Convolutional Neural Network* dirancang untuk memproses data dalam beberapa array, misalnya gambar berwarna yang memiliki tiga array 2 dimensi (2D) dengan tiga saluran warna, yaitu *Red Green Blue (RGB)*. Arsitektur *Convolutional Neural Network* disusun sebagai serangkaian lapisan. Beberapa lapisan awal terdiri dari beberapa jenis lapisan yaitu lapisan konvolusional, ReLU, dan pooling. Kemudian, lapisan terakhir yaitu fully connected layer. Secara umum, proses pada CNN terbagi menjadi dua tahapan, yaitu *feed forward propagation* (propagasi maju) dan *backward propagation* (propagasi mundur).

CNN merupakan pendekatan deep learning yang sangat sukses pertama kali di mana banyak lapisan berhasil dilatih dengan cara yang kuat. CNN adalah arsitektur yang memanfaatkan hubungan spasial dan temporal untuk mengurangi jumlah parameter yang harus dipelajari dan dengan demikian meningkatkan pelatihan *feed forward* dan *back propagation*. CNN diusulkan sebagai kerangka kerja deep learning yang membutuhkan persyaratan data pra-pemrosesan yang minimal. Di CNN, sebagian kecil dari citra diperlakukan sebagai input ke lapisan terendah dari struktur hierarkis. Informasi umumnya menyebar

melalui berbagai lapisan jaringan dimana pada setiap lapisan tersebut terdapat filter yang diterapkan untuk mendapatkan fitur yang menonjol dari data yang diamati.

Dalam hal menerapkan kecerdasan buatan dan pembelajaran mesin ke bidang medis, CNN sangat baik untuk deteksi dan klasifikasi citra penyakit. CNN dapat digunakan untuk mengklasifikasikan gambar, mengelompokkannya berdasarkan kesamaan, dan menjalankan pengenalan objek. Jaringan ini terinspirasi dalam pemrosesan korteks visual manusia dan digunakan untuk gambar medis di mana ketidakteraturan dalam morfologi jaringan dapat digunakan untuk mengklasifikasikan penyakit. CNN dapat mendeteksi pola yang sulit ditemukan oleh dokter spesialis, misalnya tahap awal penyakit pada sampel jaringan

### D. EfficientNetB7

Efektivitas penskalaan model juga sangat bergantung pada jaringan dasar. Untuk lebih meningkatkan kinerja, telah dikembangkan jaringan dasar baru dengan melakukan penelusuran arsitektur neural network menggunakan *framework AutoML MNAS*, yang mengoptimalkan akurasi dan efisiensi (FLOPS). Arsitektur yang dihasilkan menggunakan *Mobile Inverted Bottleneck Convolution (MBConv)*, mirip dengan *MobileNetV2* dan *MnasNet*, tetapi sedikit lebih besar karena peningkatan *FLOP*. Arsitektur ini kemudian disebut dengan *EfficientNet*. *EfficientNet* dipercaya sebagai arsitektur CNN yang memiliki jumlah parameter yang lebih sedikit namun memiliki akurasi yang tinggi (Tan and Le 2019).

### E. Resnet152-V2

*ResNet* adalah jenis jaringan mendalam berbasis pembelajaran residual. Pembelajaran semacam ini dapat membantu pelatihan jaringan dengan mempertimbangkan lapisan input sebagai referensi. *ResNet* memberikan solusi untuk masalah efek *vanishing gradient* dengan menggunakan *skip connection*. Ada beberapa versi dari arsitektur ini, yaitu *ResNet-18*, *ResNet-34*, *ResNet-50*, *ResNet-101*, *ResNet-110*, *ResNet-152*, *ResNet-164*, dan *ResNet-1202* (He et al. 2016).

*ResNet-152* adalah model *ResNet* dengan 152 lapisan sangat dalam yang dapat mempelajari fitur di berbagai tingkat abstraksi untuk meningkatkan kinerja. *ResNet-152* memenangkan ILSVRC 2015 dengan tingkat kesalahan 3,6%, mengungguli beberapa arsitektur, seperti *AlexNet*, *VGG-19*, dan arsitektur lainnya (Han et al. 2018). Berikut pada Tabel 1 adalah informasi mengenai model *ResNet152-V2* dan *EfficientB7* pada CNN yang telah di latih dan digunakan untuk proses klasifikasi menggunakan *ImageNet dataset*.

Tabel 1. Akurasi Arsitektur CNN

Model	Akurasi		Jumlah parameter
	Top-1	Top-5	
ResNet152 (2016)	77%	93.3%	25.6M
EfficientNetB7(2019)	84.4%	97.1%	66M

Sumber : (Khan et al. 2020)

### 3. METODE PENELITIAN

#### A. Dataset

Penelitian ini menggunakan dataset citra X-ray Paru-paru yang didapatkan secara gratis di situs data Mendeley [11]. Dataset yang digunakan terdiri dari dua kelas yaitu kelas COVID-19 dan Normal. Kelas COVID-19 berarti bahwa dataset citra X-ray diperoleh dari pasien yang positif terinfeksi COVID-19 dan kelas normal berarti bahwa dataset citra X-ray diperoleh dari orang yang tidak terinfeksi COVID-19. Total keseluruhan dataset berjumlah 6.190 citra yang terdiri dari 3.906 citra pada kelas COVID-19 dan 2.284 citra pada kelas normal. Dataset dibagi menjadi data latih dan data uji dengan persentase masing-masing 80% dan 20%. Adapun rincian pembagian jumlah data citra dapat dilihat pada Tabel 2.

Tabel 2. Pembagian data

Kelas Data	Jumlah Data
Latih	4.952
Uji	1238

#### B. Transfer Learning

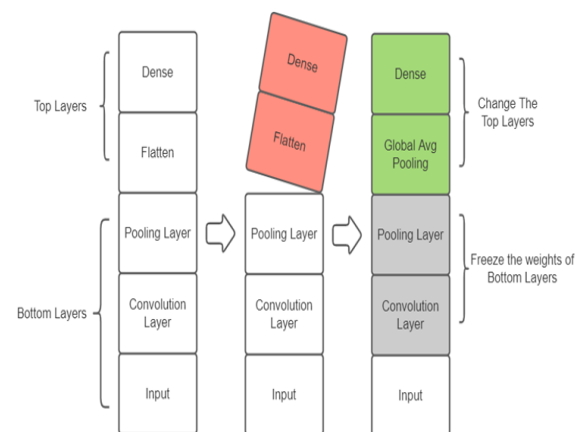
Dalam CNN, misalnya pada kasus klasifikasi citra, citra ibarat seperti makanan bagi CNN, semakin banyak citra yang dilatihkan maka kematangan model akan tercapai untuk menyelesaikan masalah dengan kinerja optimal. Bagi dataset berukuran besar tentu tidak menjadi masalah, tetapi bagi dataset berukuran kecil tidak dapat mencapai kinerja optimal. Maka dari itu, transfer learning menjadi pendekatan bagi dataset berukuran kecil untuk mencapai kinerja optimal. Transfer learning adalah salah satu pendekatan CNN, misalnya dalam klasifikasi, dengan memindahkan model yang sudah terlatih pada sebuah dataset, biasanya menggunakan Imagenet, untuk menyelesaikan masalah lainnya. *Transfer learning* dapat bekerja pada deep learning jika fitur-fitur model yang dipelajari dari model pertama bersifat umum. *Fine tuning* merupakan teknik transfer learning yang dapat dilakukan dengan menerapkan pelatihan ulang pada bagian akhir blok konvolusi dan membiarkan (tidak melatih ulang) layer konvolusi lainnya. Pelatihan ulang pada sebagian layer akhir bertujuan untuk memberikan generalisasi CNN pada dataset lain dan tetap mempertahankan generalisasi pada dataset original.

Model yang sudah terlatih ini disebut dengan *Pre-Trained Model*. *Pre-trained model* biasanya sudah dilatih pada dataset yang besar dan merupakan dataset benchmark, sehingga kualitas *pre-trained model* sudah sangat baik. Dalam penelitian ini kami melakukan transfer learning menggunakan *pre-trained CNN* tersebut dengan melatih ulang menggunakan dataset kami. *Pre-trained CNN* yang digunakan adalah *EfficientNetB7* dan *Resnet152-V2*. Kedua model ini dipilih untuk dibandingkan karena pada pengujian dengan menggunakan ImageNet dataset, *ResNet152* adalah model yang menghasilkan jumlah parameter yang sedikit meskipun tingkat akurasi yang lebih rendah dibandingkan dengan model yang datang setelahnya, sedangkan *EfficientNetB7* adalah *model state-of-the-art CNN* yang memiliki

tingkat akurasi yang tinggi namun jumlah parameter yang dihasilkan lebih banyak.

Pada gambar 4 adalah langkah kerja transfer learning yang digunakan pada penelitian ini. Adapun uraian langkah kerja *Transfer learning* dijelaskan dengan tahapan berikut:

1. Menghapus *top layer* jaringan *pre-trained network*, layer ini tidak dapat digunakan pada proses klasifikasi citra X-Ray Paru-paru karena menggunakan 1000 kelas dari dataset *ImageNet*.
2. Mengganti *top layer* pada pretrained network dengan *top layer* yang sesuai dengan kasus yang sedang diteliti yaitu berdasarkan jumlah kelas dari citra X-ray Paru-paru yaitu kelas COVID-19 dan normal.
3. Membekukan (*Freeze*) bobot pada *bottom layer* dari *pretrained network* untuk menjaga nilai di dalamnya yang berguna saat proses pelatihan.
4. Selanjutnya dilakukan pelatihan pada model yang dihasilkan pada proses pelatihan dengan menggunakan data latih.



Gambar 1. Proses *transfer learning* dengan menerapkan teknik *fine-tuning*

Setelah model dilatih menggunakan data latih, nilai-nilai bobot yang diperoleh dari proses pelatihan digunakan untuk menguji model dengan data uji dan mendapatkan hasil klasifikasi.

Langkah-langkah *transfer learning* pada pelatihan dan pengujian di atas dilakukan menggunakan *pre-trained network* dengan *EfficientNetB7* dan *Resnet152-V2*. Adapun *Hyperparameter* yang digunakan untuk melatih kedua *pre-trained model* penelitian ini disajikan pada tabel 3 berikut ini.

Tabel 3. *Setting Hyperparameter CNN*

Parameter	Value
Hidden layer units	256
Dropout	0.5
Optimizer	Adam Optimizer
Loss function	Binary cross entropy
Learning rate	0.0001
Epoch	100
Batch size	32

#### 4. HASIL DAN PEMBAHASAN

##### A. Hasil Pelatihan Model

Data latih yang berjumlah 4.952 citra dilatih dengan masing-masing arsitektur *EfficientNetB7* dan *Resnet152-V2*. Tabel 4 menunjukkan hasil akurasi dari pelatihan dan validasi data citra X-Ray dengan menggunakan proses *transfer learning* dan *hyperparameter* yang sama pada kedua *model pre-trained CNN*.

Tabel 4. Hasil Klasifikasi Data Citra X-Ray

Model CNN	Akurasi	
	Latih	Validasi
EfficientNetB7	0.9665	0.9483
Resnet152-V2	0.9677	0.9676

Berdasarkan hasil yang diperoleh, kedua model pelatihan memiliki nilai akurasi pelatihan yang tidak berbeda jauh yaitu sekitar 97% sedangkan perolehan akurasi pada proses validasi menunjukkan bahwa *ResNet152-V2* unggul 0.0193 dari *EfficientNetB7*.

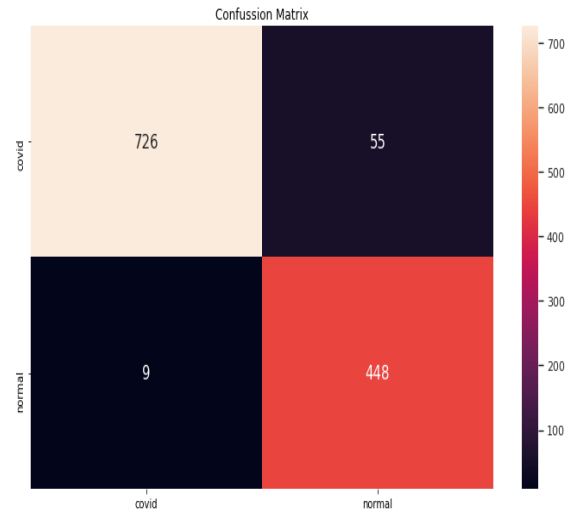
##### B. Hasil Pengujian Model

Model hasil pelatihan kemudian diimplementasikan pada data uji. Data uji berjumlah 1.857 citra X-ray Paru-paru. Setelah pengujian data, didapatkan hasil klasifikasi yang ditunjukkan pada Tabel 4. Kinerja arsitektur pada proses pelatihan tergambar dengan sangat baik pada performa implementasi modelnya pada data uji. Hasil akurasi klasifikasi model *EfficientNetB7* adalah 95% dan *Resnet152-V2* sebesar 97%.

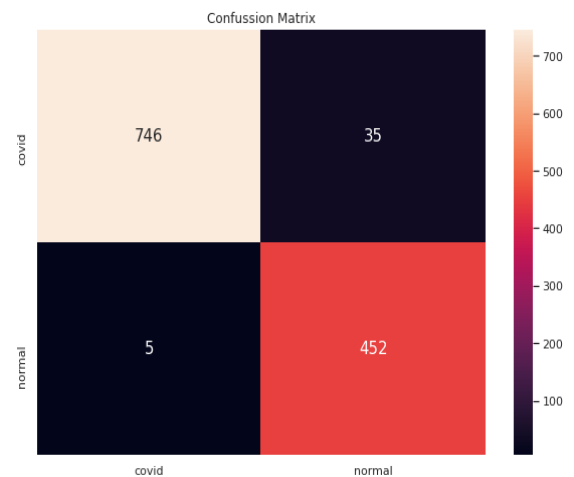
Tabel 5. Hasil Pengujian Model *EfficientNetB7* dan *Resnet152-V2*

Model CNN	Class	Precisi on	Reca ll	F1-Scor e	Accura cy
EfficientNet B7	Covid -19	0.99	0.93	0.96	0.95
	Normal	0.89	0.98	0.93	
Resnet152-V2	Covid -19	0.99	0.96	0.97	0.97
	Normal	0.93	0.99	0.96	

Hasil klasifikasi citra X-Ray Paru-paru menggunakan model *Resnet152-V2* memiliki tingkat akurasi 2% lebih tinggi dibandingkan dengan hasil klasifikasi menggunakan model *EfficientNetB7*. Perbedaan tingkat akurasi yang tidak begitu besar menunjukkan bahwa kedua model efektif untuk digunakan pada proses klasifikasi data citra X-Ray. Meski demikian, hasil penelitian ini juga mengindikasikan bahwa model *Resnet152-V2* lebih tepat digunakan untuk pengklasifikasian data citra X-Ray Paru-paru. Berikut ini adalah confusion matriks dari kedua hasil klasifikasi kedua model.



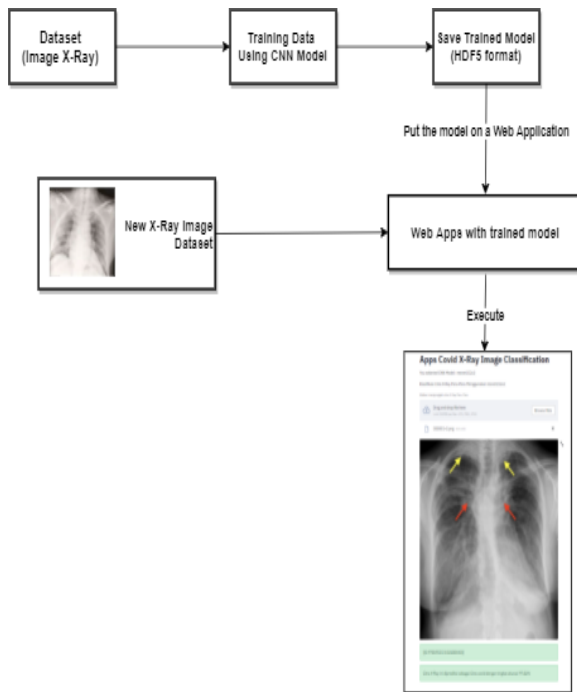
Gambar 2. Confusion Matriks hasil klasifikasi menggunakan *EfficientNetB7*



Gambar 3. Confusion matriks hasil klasifikasi menggunakan *ResNet152-V2*

##### C. Desain Sistem Aplikasi Deteksi Citra X-Ray Paru-paru terinfeksi COVID-19

Desain sistem aplikasi web seperti pada Gambar 4. Pertama, dataset citra COVID-19 di *preprocessing* terlebih dahulu agar bisa digunakan pada tahap pelatihan model. Kedua, membangun model CNN dan melakukan proses pelatihan dengan menggunakan dataset yang telah di preprosesing. Ketiga, Model yang telah dilatih akan disimpan menjadi file dalam format HDF5 agar dapat digunakan pada aplikasi web. Selanjutnya file HDF5 akan digunakan untuk membuat aplikasi web dengan menggunakan *framework Streamlit Python*. Aplikasi web digunakan untuk mendeteksi dataset Citra X-Ray Paru-paru yang baru untuk mendeteksi apakah terinfeksi COVID-19 atau tidak dengan melihat presentasi akurasi.



Gambar 4. Desain Sistem Aplikasi Web Pendeteksi Citra X-Ray terinfeksi COVID-19

## 5. KESIMPULAN

Pada penelitian ini melakukan evaluasi terhadap dua model CNN yaitu *Resnet152-V2* dan *EfficientNetB7* untuk mengukur kemampuan model dalam deteksi Citra X-ray Paru-paru terinfeksi COVID-19. Dapat disimpulkan bahwa *Resnet152-V2* mencapai kinerja lebih baik dibanding arsitektur CNN *EfficientNetB7* dalam menyelesaikan masalah klasifikasi Citra X-Ray Paru-paru berdasarkan nilai akurasi yaitu *Resnet152-V2* dengan akurasi 97% sedangkan *EfficientNetB7* dengan akurasi 95%. Capaian kinerja ini menunjukkan bahwa *Resnet152-V2* lebih tepat diimplementasikan pada klasifikasi citra X-Ray terinfeksi COVID-19. Dua model yang telah diberikan pelatihan dan pengujian selanjutnya diimplementasi ke aplikasi web untuk mendeteksi Citra-Xray yang terinfeksi COVID-19.

## 6. DAFTAR PUSTAKA

Ahuja, Sakshi, Bijaya Ketan Panigrahi, Nilanjan Dey, Venkatesan Rajinikanth, and Tapan Kumar Gandhi. 2021. "Deep Transfer Learning-Based Automated Detection of COVID-19 from Lung CT Scan Slices." *Applied Intelligence* 51(1):571–85.

Han, Seung Seog, Gyeong Hun Park, Woohyung Lim, Myoung Shin Kim, Jung Im Na, Ilwoo Park, and Sung Eun Chang. 2018. "Deep Neural Networks Show an Equivalent and Often Superior Performance to Dermatologists in Onychomycosis Diagnosis: Automatic Construction of Onychomycosis Datasets by Region-Based Convolutional Deep Neural Network." *PLoS ONE* 13(1):1–14.

He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. 2016. "Deep Residual Learning for Image Recognition." *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2016-December*:770–78.

Khan, Asifullah, Anabia Sohail, Umme Zahoor, and Aqsa Saeed Qureshi. 2020. *A Survey of the Recent Architectures of Deep Convolutional Neural Networks*. Vol. 53. Springer Netherlands.

Mishra, Chandrabhas, and D. L. Gupta. 2017. "Deep Machine Learning and Neural Networks: An Overview." *IAES International Journal of Artificial Intelligence (IJ-AI)* 6(2):66.

Shorten, Connor, Taghi M. Khoshgoftaar, and Borko Furht. 2021. "Deep Learning Applications for COVID-19." *Journal of Big Data* 8(1).

Singh, Dilbag, Vijay Kumar, Vaishali, and Manjit Kaur. 2020. "Classification of COVID-19 Patients from Chest CT Images Using Multi-Objective Differential Evolution-Based Convolutional Neural Networks." *European Journal of Clinical Microbiology and Infectious Diseases* 39(7):1379–89.

Tan, Mingxing, and Quoc V. Le. 2019. "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks." *36th International Conference on Machine Learning, ICML 2019 June*:10691–700.

WHO. 2020. "Coronavirus." Retrieved (<https://www.who.int/health-topics/coronav>).

Zhu, Na, Dingyu Zhang, Wenling Wang, Xingwang Li, Bo Yang, Jingdong Song, Xiang Zhao, Baoying Huang, Weifeng Shi, Roujian Lu, Peihua Niu, Faxian Zhan, Xuejun Ma, Dayan Wang, Wenbo Xu, Guizhen Wu, George F. Gao, and Wenjie Tan. 2020. "A Novel Coronavirus from Patients with Pneumonia in China, 2019." *New England Journal of Medicine* 382(8):727–33.