

## DEEP PRE-TRAINED MULTI MODEL CONVOLUTION NEURAL NETWORK UNTUK DIAGNOSA COVID 19 PADA CITRA RONTGEN DADA

Muhammad Faishol Amrulloh, Moch. Lutfi, Wahyu Agung Nurcahyo  
Prodi Teknik Informatika, Universitas Yudharta Pasuruan  
faishol@yudharta.ac.id, moch.lutfi@yudharta.ac.id, wa264723@gmail.com

### ABSTRAK

Covid 19 merupakan virus yang dapat menyebar ke berbagai negara termasuk negara Indonesia, virus ini dapat mengakibatkan infeksi saluran pernafasan yang disebabkan oleh corona. Untuk mengetahui akibat terjangkit virus tersebut dapat dilakukan dengan tes medis meliputi swab, cek darah maupun scan radiologi rontgen dada. Pada penelitian yang dilakukan untuk identifikasi virus covid 19 menggunakan pada citra rontgen dada dengan metode yang diusulkan model convolution neural network yang mampu menghasilkan performa paling baik dalam mendeteksi penyakit. Pengujian dilakukan dengan menggunakan empat pre-trained ensemble model yang telah disediakan oleh Keras yaitu VGGNet, GoogleNet, DenseNet, dan NASNet tingkat akurasi training yang dihasilkan adalah 97% dan akurasi validasi yang dihasilkan adalah 85% akan tetapi metode yang diusulkan pada penelitian ini waktu komputasi yang dihasilkan sangat baik yaitu 0 detik dari hasil tersebut dapat disimpulkan metode penggabungan (ensemble) ini sangat baik jika diimplementasikan terhadap data penelitian yang digunakan.

**Kata kunci:** Deep Learning, Rontgen dada, CNN, Deep Pre-trained.

### 1. PENDAHULUAN

Gelombang pasang surut pandemi mengguncang berbagai kota di bumi sebab Penyakit Coronavirus 2019 ataupun Covid-19, di mana penyakit ini mencemari saluran respirasi yang diakibatkan oleh tipe Covid. Penyakit Covid ataupun Covid-19 merupakan peradangan yang bisa mencemari sistem respirasi. Lebih dari 2 tahun kita sudah hadapi pandemi Covid-19 semenjak awal kali muncul di kota Wuhan Cina menjelang akhir Desember tahun 2019 [1]. Dalam beberapa bulan virus ini dengan cepat menyebar ke berbagai belahan dunia [2]. Per tanggal 22 Desember 2021, terdapat 275 juta terjangkit positif Covid-19 serta dilaporkan meninggal dunia sejumlah 5,3 juta orang secara keseluruhan [3]. Gejala yang terjangkit akibat covid antara lain panas, demam dan sesak nafas. Permasalahan yang lebih serius akibat covid yang menyebabkan inflamasi pada paru-paru atau juga sering disebut dengan pneumonia [4]. Salah satu teknik yang sering digunakan mendeteksi pada covid adalah menggunakan citra rontgen dada. Rontgen dada adalah digunakan untuk mendeteksi keadaan paru-paru pasien penderita covid. Hasil dari scan rontgen dada digunakan untuk analisa keadaan paru-paru pasien yang terinfeksi oleh virus corona maupun tidak. Pemanfaatan rontgen dada digunakan sebagai alat alternatif oleh para pakar dokter sebagai solusi deteksi dengan alasan setiap rumah sakit pasti mempunyai alat scan rontgen sehingga tidak lagi diperlukan alat tambahan [5].

Berdasarkan penelitian sebelumnya, metode Convolutional Neural Network sudah banyak digunakan untuk pengenalan objek. Beberapa arsitektur pada metode Convolutional Neural Network yang sering digunakan oleh para penelitian antara VGG [6], InceptionV3 [7], ResNet,

InceptionResNetV2 [8], DenseNet [9], Xception [10] dan MobileNet [11].

Penelitian yang dilakukan oleh [12] menggunakan model ResNet, InceptionNet V3, dan XceptionNet. Penelitian yang dilakukan menggunakan dataset sejumlah 6432 dari citra rontgen dada dan masing-masing data dibagi menjadi 85% sebagai data latih dan 15% sebagai data uji. Sedangkan ukuran citra dirubah menjadi 128x128 piksel tujuan dari perubahan citra rontgen dada untuk mempercepat proses training data. Awal pengujian yang melibatkan model XceptionNet mencapai akurasi 100% pengujian berikutnya menggunakan model arsitektur InceptionNet V3 mencapai 99% dari akurasi yang didapatkan. Model ResNet menghasilkan kinerja sangat baik dalam pengujian terakhir dan hasilnya mencapai akurasi 98% pada data uji dengan ketepatan 93% pada pengujian model arsitektur XceptionNet menghasilkan akurasi sebesar 97%. Meskipun demikian, dalam hal pengujian akurasi dan validasi, masing-masing dari ketiga model tersebut menghasilkan overfitting data, sedangkan model ResNet menghasilkan tingkat overfitting yang sangat besar.

Berdasarkan masalah penelitian diatas maka penelitian ini mengusulkan metode transfer learning dengan penggabungan beberapa arsitektur meliputi VGGNet, GoogleNet, DenseNet, serta NASNet diharapkan dapat mengurangi overfitting data serta digunakan untuk meningkatkan kinerja hasil dari penelitian sebelumnya, dan pengujian hasil serta penerapan sistem yang dilakukan terdiri dari akurasi, loss function dan waktu komputasi yang dibutuhkan.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Penelitian yang dilakukan menggunakan metode DDCNNC dengan 5 arsitektur yang terbagi menjadi 2 tahap uji, pertama menguji 3 arsitektur yaitu LeNet-5, VGG-16, dan ResNet-18. yang kedua menguji 2 arsitektur yaitu VGG-16 dan ResNet-18. Hasil eksperimen menunjukkan bahwa model yang diusulkan tidak hanya meningkatkan akurasi deteksi, tetapi juga mengurangi waktu pelatihan [13].

Penelitian lain mengusulkan tiga jenis klasifikasi yaitu pneumonia normal vs pneumonia, pneumonia bakterial vs virus, dan pneumonia normal, bakteri, dan virus. Dalam penelitian ini menggunakan Convolutional Neural Network (CNN) pre-trained model dengan menerapkan arsitektur yang berbeda AlexNet, ResNet18, DenseNet201, dan SqueezeNet. Akurasi klasifikasi gambar normal dan pneumonia, gambar pneumonia bakteri dan virus, dan pneumonia normal, bakteri, dan virus berturut-turut adalah 98%, 95%, dan 93,3% [14].

Teknik pelatihan untuk mengklasifikasikan image X-ray ke dalam tiga kelas yaitu normal, pneumonia, dan COVID-19, berdasarkan dua sumber dataset terbuka yang berisi 180 image X-ray, penelitian ini mengusulkan model gabung Xception dan ResNet50V2 model ini mampu menghasilkan akurasi terbaik dengan memanfaatkan beberapa fitur ekstraksi. Akurasi rata-rata keseluruhan untuk semua kelas adalah 91.4% [15].

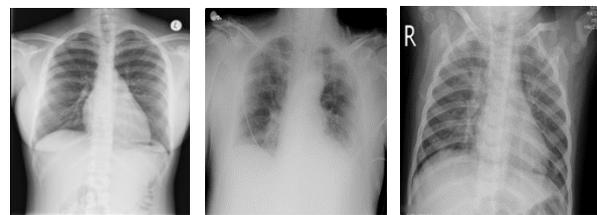
Modifikasi model ResNet digunakan untuk klasifikasi COVID-19, infeksi non-COVID-19, dan kontrol normal menggunakan gambar CT. Hasil menunjukkan bahwa metode yang diusulkan mencapai akurasi uji 99,6% pada dataset citra CXR lima kategori dan akurasi uji 99,3% pada dataset citra CT. Enam arsitektur CNN canggih dan dua model deteksi COVID-19 spesifik, yaitu COVID-Net dan COVIDNet-CT digunakan dalam studi banding. Dua dataset benchmark dan dataset gambar CXR yang menggabungkan delapan sumber gambar CXR yang berbeda digunakan untuk mengevaluasi kinerja model di atas. Hasilnya menunjukkan bahwa metode yang diusulkan mengungguli model komparatif dalam akurasi klasifikasi, sensitivitas, dan presisi [16].

Menggunakan pendekatan deep learning convolution neural network dengan fokus pada klasifikasi gambar rontgen dada Covid-19. Basis data terdiri dari gambar rontgen dada Covid-19, pneumonia normal dan virus dengan 800 sampel berbeda di setiap kelas. Penelitian ini mengevaluasi model pada 500 gambar dan jaringan mencapai tingkat sensitivitas 95% dan tingkat spesifisitas 97%. Arsitektur DenseNet121 tampil sedikit lebih baik, dibandingkan dengan jaringan lainnya [17]. Kinerja yang dicapai dengan metode yang diusulkan sangat baik dan tingkat akurasi lebih tinggi dengan kumpulan dataset yang lebih besar. Selain tingkat sensitivitas dan spesifisitas, model yang diusulkan juga dibandingkan pada

karakteristik (ROC), dan area kurva (AUC) dari masing-masing model.

2.2. Corona Viruses Disease atau COVID-19

Adalah virus yang dapat menular disebabkan oleh SARS-CoV-2, penyakit ini dengan cepat menyebar ke berbagai negara termasuk Indonesia. Hal tersebut membuat beberapa negara memberlakukan aturan lockdown untuk mencegah akan menularnya virus. Orang yang terjangkit akibat covid memiliki ciri batuk, demam, sesak seperti infeksi pada paru-paru. Beberapa negara juga mengkonfirmasi bahwa banyak penduduknya banyak yang meninggal akibat virus corona. Gejala lain yang terinfeksi virus corona meliputi diare, sakit kepala, hilangnya rasa dan anosmia gejala-gejala ini umumnya muncul dalam kurun waktu 2 hari sampai 2 minggu.

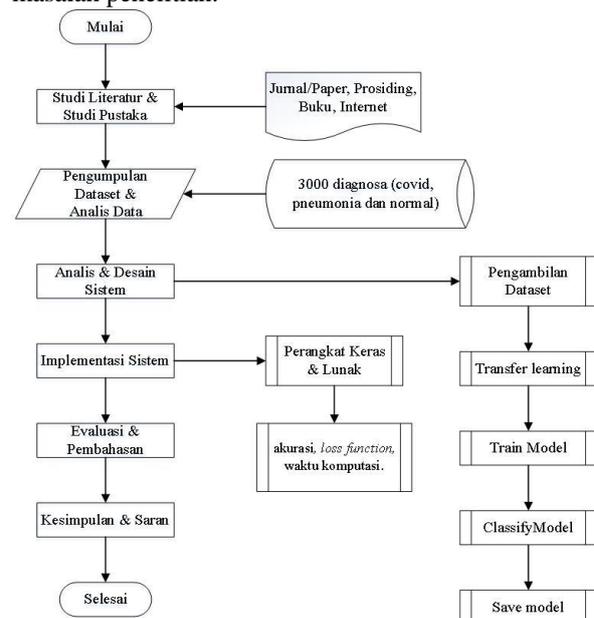


(a) normal (b) covid-19 (c) pneumonia

Gambar 1. Rontgen Dada

3. METODE PENELITIAN

Metode yang dilakukan dalam penelitian adalah hasil dari metode penelitian eksperimen. Penelitian eksperimen mencakup investigasi hubungan sebab-akibat menggunakan pengujian yang dikontrol sendiri sering kali mengalami kendala pada penelitian semi eksperimen karena tidak cukupnya akses sampel, oleh karena itu penelitian eksperimen biasanya digunakan untuk pengembangan, evaluasi dan pemecahan pada masalah penelitian.



Gambar 2. Tahapan Penelitian

1. Studi Literatur

Pada tahap ini peneliti melakukan pengumpulan bahan sebagai refrensi maupun perbandingan dengan penelitian sebelumnya seperti halnya pencarian renfrensi jurnal atau paper, buku, proceeding maupun metode penelitian yang dilakukan oleh peneliti lain.

2. Pengumpulan dataset

Dataset rontgen data diambil salah satu sample dari rumah sakit rs. sahabat dan untuk data latih dan training diambil dari data public kangle.com. Dataset yang digunakan sebanyak 3000 dataset yang terdiri dari 1000 normal, 1000 covid, 1000 pneumonia.

3. Analisis Dataset rontgen dada

Proses awal pengolahan dataset rontgen data dilakukan untuk memisahkan antara normal, covid, dan pneumonia. Analisis data ini dilakukan bersama pakar dokter yang ahli dalam penyakit covid.

4. Desain sistem

Desain sistem adalah bagian dari tahap perencanaan, design sistem dan tahapan membangun sistem yang akan kembangkan dengan metode ensemble yang diusulkan.

5. Implementasi sistem

Implementasi code sistem yang dibuat dilakukan dengan bahasa python di google colab.

6. Uji coba dan evaluasi

Tahapan dilakukan untuk proses training dan testing pada metode multi model ensemble dan kemudian dilakukan evaluasi terhadap metode meliputi hasil akurasi, loss funtion dan waktu komputasi.

3.1. Preprocessing

Tahap ini merupakan tahap proses persiapan gambar yang akan dirubah menjadi ukuran dan kemudian dilakukan proses training untuk melihat dampak terhadap hasil presisi pada setiap model. Proses merubah ukuran gambar untuk mengurangi waktu komputasi dan mempercepat proses training maupun testing[18]. Dataset kemudian dipisahkan menjadi tiga bagian meliputi dataset training, dataset validasi dan dataset testing. Dataset training digunakan untuk melatih dar metode multi model ensembl, dataset validasi digunakan sebagai memvalidasi dari hasil proses training, sementara pada bagian dataset testing digunakan untuk testing atau ujicoba ketepatan terhadap data.

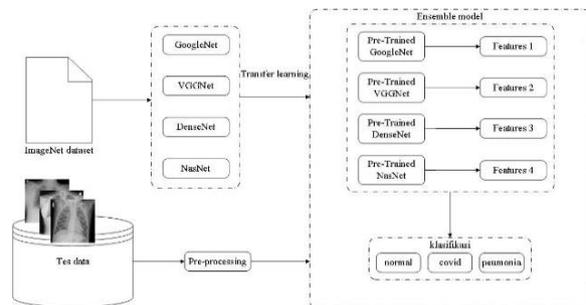
3.2. Convolutional Neural Network

Convolutional Neural Network [19][20] merupakan metode klasifikasi maupun prediksi yang digunakan pada data gambar, teks dan suara. Pada umumnya metode convolutional neural network mempunyai tiga layer antara lain pooling layer, convolutional layer dan fully connected layer. Pooling dan convolutional layer digunakan untuk ekstraksi informasi pada gambar, sedangkan fully connected

layer digunakan untuk proses klasifikasi maupun prediksi serta memberikan label yang paling tepat sebagai hasil.

3.3. Transfer Learning

Transfer Learning [19][21] adalah teknik memanfaatkan model yang sudah dilakukan proses training pada data sebelumnya, proses ini digunakan untuk klasifikasi dataset baru sehingga tidak lagi diperlukan proses training dari awal hanya dilakukan penyesuaian pada bagian model akhir. Secara garis besar arsitektur convolutional neural network terdiri dari beberapa layer, layer tersebut digunakan untuk proses ekstraksi pada fitur dataset.



Gambar 3. model transfer learning yang diusulkan

3.4. Ensemble model features extraction

Model deep convolution neural network digunakan untuk ekstraksi fitur. Fitur ekstraksi disediakan pada lapisan full connected untuk klasifikasi akhir. Pada penelitian ini menggunakan ensembl dari empat struktur deep convolution neural network untuk ekstraksi fitur. Ensemble ini menggunakan model VGGNet, DenseNet, GoogleNet, dan NASNet yang merupakan bagian dari model deep learning.

3.5. VGGNet

Arsitektur VGGNet [22] adalah model pengembangan dari arsitektur alexnet prinsip kerja dari arsitektur ini memperbanyak pada proses ekstraksi fitur layer convolution sehingga bisa dapat mempresentasikan citra untuk proses klasifikasi.

3.6. DenseNet

Dense convolutional networks (DenseNet) diperkenalkan oleh[9] struktur ini dibangun dari masing-masing layer yang terhubung dengan layer lainnya. Dense connection merupakan bagian dari arsitektur densenet dan fungsinya untuk mengurangi terjadinya overfitting ketika jumlah data dalam sekala besar. Pada penelitian ini model densenet yang digunakan adalah densenet121.

3.7. GoogleNet

GoogleNet merupakan arsitektur yang dikembangkan oleh perusahaan google pada tahun 2015, arsitektur ini juga pernah peringkat pertama untuk kompetisi ImageNet Large Scale Visual Recognition

Challenge dan pada waktu itu arsitektur ini mendapat predikat arsitektur dengan tingkat kinerja terbaik. Ukuran layer yang dimiliki googleNet adalah 144 layer untuk ukuran input 224x224x3 [23]. Arsitektur ini mempunyai kelebihan pada inception modules yang tidak akan dimiliki oleh arsitektur lainnya, beberapa inception modules terdiri dari convolution kecil, yang berfungsi untuk mereduksi jumlah parameter tanpa mengurangi kinerja jaringan.

**3.8. NasNet**

Diperkenalkan oleh Google Brain pada tahun 2018, ide gagasan pertama diusulkan yaitu transferabilitas. Konvolusional lapisan ini disebut sebagai sel, untuk memecahkan masalah klasifikasi pada himpunan data CIFAR10 dan beberapa tumpukan sel tersebut digunakan untuk memecahkan masalah klasifikasi ImageNet.

**3.9. Confusion Matrix**

Confusion matrix adalah matriks perbandingan antara hasil prediksi dan nilai sebenarnya, yang dapat dengan jelas menunjukkan rincian prediksi setiap kategori klasifikasi maupun prediksi [24][25][26]. Evaluasi pengukuran data melalui presisi, recall dan akurasi. Hasilnya direpresentasikan ke dalam bentuk tabel klasifikasi. Berikut ini rumus perhitungan dari confusion matrix.

Tabel 1. Confusion Matrix

Confusion Matrix		Prediksi	
		Positif	Negatif
Actual	Positif	a	b
	Negatif	c	d
Positif Prediktif		Sensitivity	Specificity
a/(a+b)		a/(a+c)	d/(b+d)
Negatif Predictif		Akurasi = (a+d)/(a+b+c+d)	
d/(d+c)			

**4. HASIL DAN PEMBAHASAN**

Pada penelitian ini perangkat keras (software) yang digunakan adalah Core i7-6600U@2.60GHz, Ram DDR4L 16GB, SSD NVMe 512GB dan untuk kebutuhan perangkat lunak (software) yang diperlukan adalah windows 10 serta chrome dan google colab digunakan untuk implementasi coding maupun evaluasi hasil dari metode yang diusulkan dalam penelitian ini. Pada tahap implementasi source code di program python dengan memanfaatkan Google Colab parameter *transfer learning* yang di gunakan adalah model *sequential*, *optimization* menggunakan Adam, *Learning rate* 0.0001, *Activation Softmax*, dan *Epoch* 30. Sedangkan hasil akurasi yang didapatkan dengan menggunakan parameter yang di ditentukan menghasilkan tingkat akurasi yang cukup baik, berikut tabel hasil akurasi dengan multi model ensemble.

Tabel 2. Hasil Akurasi Multi Model Ensemble.

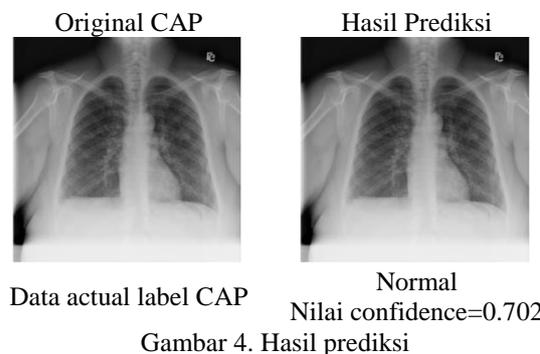
Learning_rate	0.0001		
Data	Train	Valid	Waktu komputasi
Accuracy	97%	85%	0 detik
Error_rate	0.39	0.57	

Sedangkan hasil rata-rata dari keseluruhan pengujian metode multi model ensemble dengan tabel confusion matrix adalah sebagai berikut:

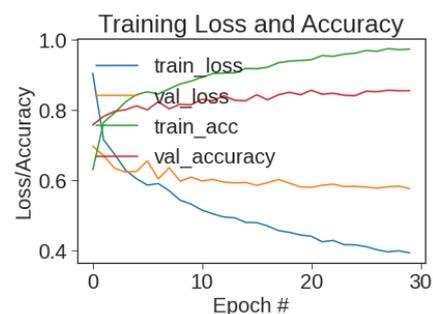
Tabel 3. Hasil confusion matrix

	precision	recall	f1score	support
CAP	0.90	0.86	0.88	1000
COVID 19	0.82	0.80	0.81	154
normal	0.87	0.91	0.89	1000
accuracy			0.88	2154
macro avg	0.87	0.86	0.86	2154
weight avg	0.88	0.88	0.88	2154

Untuk testing ketepatan terhadap data terlebih dahulu dilakukan traingin dengan jumlah 1000 data selanjutnya dilakukan testing terhadap data CAP dengan jumlah 1000 data akan tetapi yang digunakan sebagai parameter uji ketepatan digunakan salah satu data sampel pada gambar CAP/00eeb3c9-a892-4fac-a67a-aaa6cc7ffd5c.png hasil percobaan dengan metode yang diusulkan adalah normal sedangkan nilai confidence nya adalah 0.702, berikut tabel hasil percobaan.



Setelah dilakukan proses traning dan validasi terhadap dataset yang dipakai tahap selanjutnya dilakukan proses visualisasi grafik, di bawah ini adalah grafik hasil akurasi dan loss funtion.



Gambar 5. Grafik akurasi dan error rate

Berdasarkan gambar 5 dan tabel 2 diatas dapat disimpulkan bahwa menggunakan deep pre-trained model penggabungan metode (ensemble) dengan parameter squential, epoch 30, learning rate 0.0001 dan dataset training berjumlah 1000 dari masing-masing data yang digunakan. Pada impementasi ensemble atau penggabungan dari metode GoogleNet, VGGNet, DenseNet serta NasNet tingkat akurasi training yang dihasilkan adalah 97% sedangkan untuk akurasi validasi yang dihasilkan adalah 85% dan waktu komputasi yang dihasilkan dengan menerapkan penggabungan metode pada penelitian ini adalah 0 detik. Dan dari hasil yang didapatkan bahwa metode ensemble yang diterapkan pada dataset penelitian sangat baik untuk digunakan.

## 5. KESIMPULAN DAN SARAN

Hasil kesimpulan dari penelitian yang sudah dilakukan dengan penggabungan metode(ensemble) terdiri model GoogleNet, VGGNet, DenseNet serta NasNet tingkat akurasi training yang dihasilkan adalah 97% dan error rate yang hasilkan 0.39. sedangkan hasil akurasi validasi yang dihasilkan adalah 85% dengan error ratenya 0.57%, akan tetapi metode yang diusulkan pada penelitian ini waktu komputasi yang dihasilkan sangat baik yaitu 0 detik dari hasil tersebut dapat disimpulkan metode penggabungan (ensemble) ini sangat baik jika diimplementasikan terhadap data penelitian yang digunakan.

## DAFTAR PUSTAKA

- [1] W. Hastomo, "Diagnosa COVID-19 Chest X-Ray Dengan Convolution Neural Network Arsitektur Resnet-152," *KERNEL J. Ris. Inov. Bid. Inform. dan Pendidik. Inform.*, vol. 2, no. 1, pp. 26–33, 2021, doi: 10.31284/j.kernel.2021.v2i1.1884.
- [2] M. Parwanto, "Virus Corona (2019-nCoV) penyebab COVID-19," *J. Biomedika dan Kesehatan*, vol. 13, no. 8, pp. 751–752, 2020, doi: 10.1038/nsmb1123.
- [3] E. P. Prasetya, M. Azmir, and R. Amerti, "Perbandingan Performa Model Machine Learning untuk Klasifikasi COVID-19 Berdasarkan Rontgen Dada," 2021, doi: 10.5281/zenodo.5813249.
- [4] P. Parhizkar Roudsari *et al.*, "Auxiliary role of mesenchymal stem cells as regenerative medicine soldiers to attenuate inflammatory processes of severe acute respiratory infections caused by COVID-19," *Natl. Libr. Med.*, vol. 21, no. 3, pp. 405–425, 2020, doi: 10.1007/s10561-020-09842-3.
- [5] M. P. K. Buyut Khoirul Umri, Ema Utami, "Comparative Analysis of CLAHE and AHE on Application of CNN Algorithm in the Detection of COVID-19 Patients," *2021 4th Int. Conf. Inf. Commun. Technol.*, pp. 203–208, 2021.
- [6] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
- [7] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," *2016 IEEE Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2818–2826, 2016, doi: 10.1109/CVPR.2016.308.
- [8] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-ResNet and the impact of residual connections on learning," *Proc. Thirty-First AAAI Conf. Artif. Intell.*, pp. 4278–4284, 2017.
- [9] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 2261–2269, 2017, doi: 10.1109/CVPR.2017.243.
- [10] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 1800–1807, 2017, doi: 10.1109/CVPR.2017.195.
- [11] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>.
- [12] R. Jain, M. Gupta, S. Taneja, and D. J. Hemanth, "Deep learning based detection and analysis of COVID-19 on chest X-ray images," *Appl. Intell.*, vol. 51, no. 3, pp. 1690–1700, 2021, doi: 10.1007/s10489-020-01902-1.
- [13] X. Li, M. Zhai, and J. Sun, "DDCNNC: Dilated and depthwise separable convolutional neural Network for diagnosis COVID-19 via chest X-ray images," *Int. J. Cogn. Comput. Eng.*, vol. 2, no. April, pp. 71–82, 2021, doi: 10.1016/j.ijcce.2021.04.001.
- [14] C. X-ray, T. Rahman, M. E. H. Chowdhury, and A. Khandakar, "applied sciences Transfer Learning with Deep Convolutional Neural Network ( CNN ) for Pneumonia Detection Using."
- [15] M. Rahimzadeh and A. Attar, "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 Med. Unlocked*, vol. 19, p. 100360, 2020, doi: 10.1016/j.imu.2020.100360.
- [16] G. Jia, H. K. Lam, and Y. Xu, "Classification of COVID-19 chest X-Ray and CT images using a type of dynamic CNN modification method," *Comput. Biol. Med.*, vol. 134, no. April, p. 104425, 2021, doi: 10.1016/j.compbimed.2021.104425.
- [17] J. V. Pranav, R. Anand, T. Shanthy, K. Manju, S. Veni, and S. Nagarjun, "Detection and identification of COVID -19 based on chest

- medical image by using convolutional neural networks,” *Int. J. Intell. Networks*, vol. 1, no. December, pp. 112–118, 2020, doi: 10.1016/j.ijin.2020.12.002.
- [18] D. Varshni, K. Thakral, L. Agarwal, R. Nijhawan, and A. Mittal, “Pneumonia Detection Using CNN based Feature Extraction,” *Proc. 2019 3rd IEEE Int. Conf. Electr. Comput. Commun. Technol. ICECCT 2019*, 2019, doi: 10.1109/ICECCT.2019.8869364.
- [19] C. C. Aggarwal, *Neural Networks and Deep Learning*. 2018.
- [20] I. G. and Y. B. and A. Courville, *Deep learning*, vol. 29, no. 7553. 2016.
- [21] D. Sarkar, R. Bali, and T. Ghosh, *Hands-On Transfer Learning with Python Implement Advanced Deep Learning and Neural Network Models Using TensorFlow and Keras*. 2018.
- [22] V. Atliha and D. Sesok, “Comparison of VGG and ResNet used as Encoders for Image Captioning,” *2020 IEEE Open Conf. Electr. Electron. Inf. Sci. eStream 2020 - Proc.*, pp. 1–4, 2020, doi: 10.1109/eStream50540.2020.9108880.
- [23] S. Wan, Y. Liang, and Y. Zhang, “Deep convolutional neural networks for diabetic retinopathy detection by image classification,” *Comput. Electr. Eng.*, vol. 72, pp. 274–282, 2018, doi: 10.1016/j.compeleceng.2018.07.042.
- [24] Z. Jiang, Z. Dong, W. Jiang, and Y. Yang, “Recognition of rice leaf diseases and wheat leaf diseases based on multi-task deep transfer learning,” *Comput. Electron. Agric.*, vol. 186, no. April, p. 106184, 2021, doi: 10.1016/j.compag.2021.106184.
- [25] M. Sokolova and G. Lapalme, “A systematic analysis of performance measures for classification tasks,” *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, 2009, doi: 10.1016/j.ipm.2009.03.002.
- [26] A. S. Rizal and M. Lutfi, “PREDIKSI HASIL PEMILU LEGISLATIF MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR BERBASIS BACKWARD ELIMINATION,” *J. Resist. (Rekayasa ...)*, 2020, [Online]. Available: <https://ejournal.stiki-indonesia.ac.id/index.php/jurnalresistor/article/view/517>.