

KLASIFIKASI COVID-19 CHEST X-RAY DENGAN TIGA ARSITEKTUR CNN (RESNET-152, INCEPTIONRESNET-V2, MOBILENET-V2)

Widi Hastomo, Eko Hadiyanto dan Sutarno
STMIK Jakarta STI&K
Jl. BRI No.17, Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140
widie.has@gmail.com

ABSTRAK

Dalam dekade terakhir ini pemanfaatan mesin learning, khususnya Convolution Neural Network (CNN) telah banyak membantu dunia kesehatan. Dengan melakukan proses pelatihan dari sejumlah besar dataset image, CNN mampu mengklasifikasikan image tak berlabel dengan cepat dan akurasi lebih tinggi dibandingkan metode mesin learning lainnya. Penelitian ini bertujuan mengoptimasi dari tiga arsitektur CNN (ResNet-152, InceptionResNet-V2, dan MobileNet-V2) untuk mengklasifikasi penyakit covid-19, dengan melakukan training 4000 dataset image Chest x-ray. Hasil akurasi testing dari ResNet-152 yaitu 99%, lebih tinggi dibandingkan InceptionResNet-V2 hasil 98%, dan MobileNet-V2 hasil 93%. dengan presisi tiap kelas adalah Covid (99%), Lung_Opacity (97%), Normal (99%), Viral_Pneumonia (99%).

Kata Kunci : MobileNet, ResNet, InceptionResNet, Convolution Neural Network, Chest X-Ray.

PENDAHULUAN

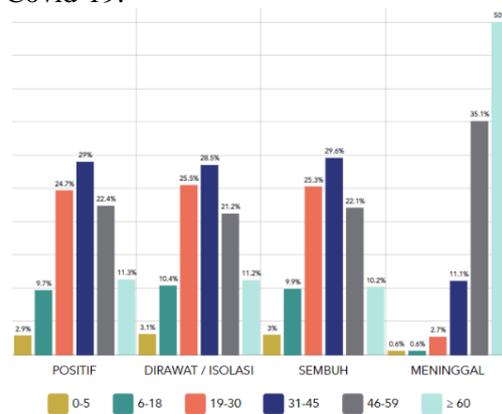
Varian baru covid-19 dengan kemampuan sebaran sangat tinggi, telah memecahkan rekor tingkat kematian tertinggi di dunia. Dalam sehari sekitar 400.000 lebih pasien terkonfirmasi positif di India, telah melumpuhkan lembaga medis dan tenaga kesehatan dalam menangani jumlah pasien yang sangat besar[1].

Tanggal 23 Juni 2021 Pemerintah Indonesia melaporkan jumlah kasus terkonfirmasi Covid-19 mencapai 2.033.421 jiwa [2]. Hal ini berdampak pada kebijakan Pemerintah Hong Kong melarang seluruh penerbangan dari Indonesia. Larangan itu menyusul status Indonesia yang berubah menjadi negara A1 (*Extremely high risk*)[3].

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

Pada grafik 1 terlihat data sebaran penyintas Covid-19 berdasarkan kategori

umur. Mulai umur 0-5 tahun hingga lebih dari 60 tahun. Dari kategori tersebut antara umur 46-59 tahun paling tinggi terdampak Covid-19.



Grafik 1. Kelompok umur positif covid-19[4].

Diagnosa covid-19 secara akurat dapat dilakukan dari *image chest x-ray*, namun memerlukan keahlian khusus para medis untuk dapat membaca data image tersebut. Karena terbatasnya jumlah para medis ini, menjadikan waktu lama (1-2 minggu) untuk dapat memperoleh hasil diagnosa. *Artificial Intelligence* (AI) khususnya metode *Convolution Neural Network* (CNN), mampu memprediksi *image chest x-ray* terhadap penyakit covid-19.

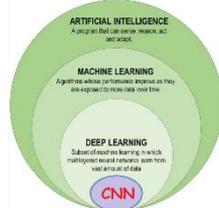
Era teknologi saat ini hampir semuanya melibatkan AI dan *deep learning* (DL)

adalah teknik yang paling banyak dipergunakan dalam pendekatan komputasi dalam bidang *Machine Learning* (ML). Banyak aplikasi yang dibentuk dengan melibatkan ML[5]–[11]. Jenis DL yang paling luas pemanfaatannya dalam kehidupan manusia adalah Convolutional Neural Network (CNN)[12]–[14],[15].

Penelitian ini bertujuan untuk memperoleh hasil terbaik dari tiga arsitektur CNN untuk mendeteksi covid-19 dari *image chest x-ray*.

METODE PENELITIAN

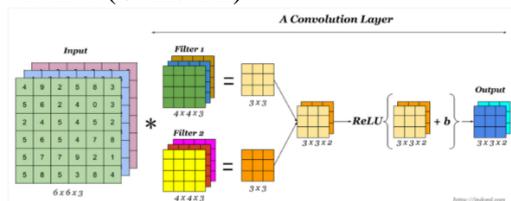
Kemampuan untuk dapat membedakan *object image*, maka teknik ini lebih dikenal dengan CNN (Gambar 1). Beberapa proses dan istilah dalam CNN akan dijelaskan secara singkat pada sub bagian ini.



Gambar 1. Klasifikasi CNN dalam AI

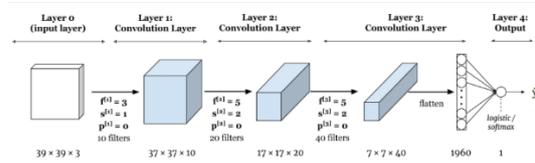
Convolutional Neural Network (CNN)

Pemikiran awal CNN adalah jaringan saraf (*neuron*) di manusia dan binatang [16]. 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 3, channel menyatakan nilai *depth* dalam matrik tersebut. Akhir dari rangkaian lapisan CNN menghasilkan model kernel, kemudian dilanjutkan dengan proses *fully connected*. Hal ini bertujuan untuk mengklasifikasikan *image* dari suatu label tertentu. (Gambar 2)



`cnn_model = models.Sequential()`

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



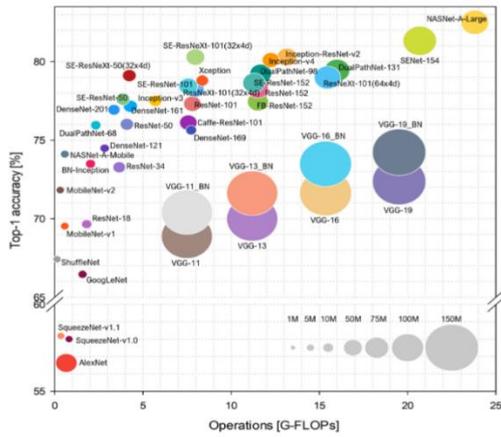
```
cnn_model = models.Sequential()
cnn_model.add(layers.Conv2D(32,(3,3),
activation='relu',
input_shape=(39,39,3)))
cnn_model.add(layers.Conv2D(64,(5,5),
activation='relu'))
cnn_model.add(layers.Conv2D(64,(5,5),
activation='relu'))
cnn_model.add(layers.Flatten())
```

Gambar 2. Proses konvolusi (atas) yang merupakan bagian dari lapisan CNN secara keseluruhan (bawah)[17].

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[12], *imagenet, coconut* dll) (Gambar 3). Namun banyak arsitektur lebih cenderung menambah lapisan menjadi sangat dalam ketimbang merancang suatu design struktur dengan metode baru. Hal ini mengakibatkan diperlukannya performansi komputer yang tinggi untuk dapat menjalankan arsitektur tersebut [18].

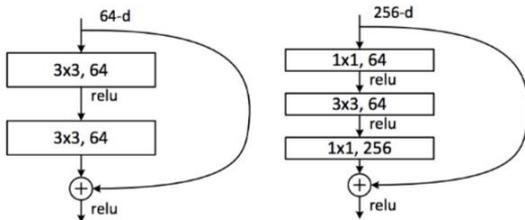
Dalam penelitian ini akan dicoba beberapa arsitektur yang mampu dilaksanakan oleh komputer yang ada, dengan sedikit melakukan penyesuaian agar memperoleh hasil yang diinginkan. Tiga arsitektur yang dipergunakan dan dibandingkan dalam penelitian ini adalah ResNet-152, InceptionResNet-V2, dan MobileNet-V2. Arsitektur ini akan melakukan proses *training* dan pengujian dengan menggunakan data set *image chest x-ray* untuk mendeteksi keberadaan jenis penyakit covid-19.



Gambar 3. Komparasi akurasi arsitektur CNN berdasarkan ILSVRC [18]

ResNet-152

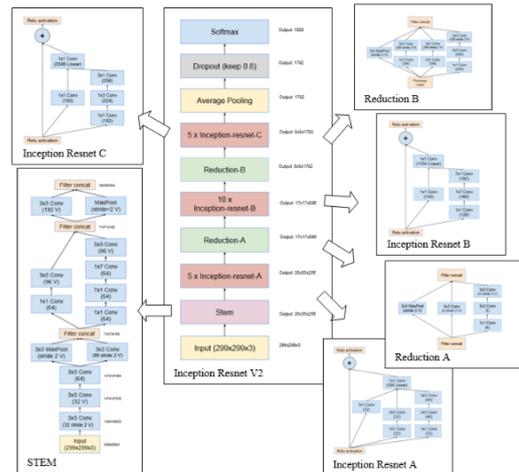
ResNet-152 adalah lapisan dengan kedalaman 152 lapisan. Model dengan jaringan lapisan dalam seperti ini cenderung akan menimbulkan *overfitting* dan *vanishing gradient*. He Kaiming dan Sun Jian pada tahun 2015 mempergunakan teknik residual blok dan *bottleneck* untuk mengatasi efek *overfitting* tersebut [19]. (Gambar 4)



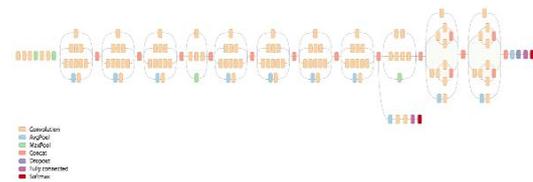
Gambar 4. Blok Residual (kiri) dan struktur bottleneck (kanan)[20]

InceptionResNet-V2

Sebagai upaya pengembangan CNN, Szegedy (2014) memperkenalkan *Inception* dalam papernya yang berjudul “*Going Deeper with Convolution*”[21]. Convolution adalah upaya ekstraksi *image* untuk memperoleh model dalam bentuk matrik kernel. Proses ini dilakukan dengan melakukan filterisasi yang bergeser dengan nilai *stride* tertentu pada suatu input *image*. Selanjutnya hasil dari *convolution* menjadi input bagian *fully connected* untuk proses klasifikasi[22].



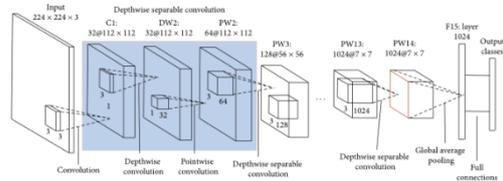
Gambar 5. Blok modul Inception Resnet V2

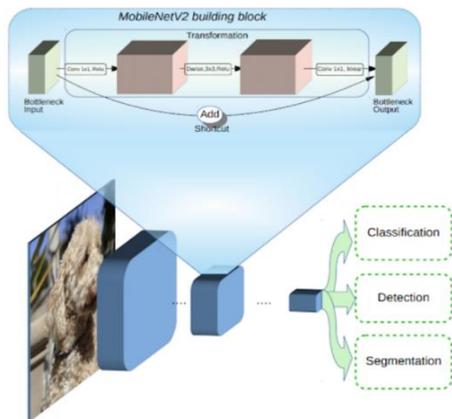


Gambar 6. Diagram keseluruhan Inception Resnet-V2[23]

MobileNet-V2

Penggunaan *feature inverted* residual blok dan *bottleneck* membedakan mobilenet versi 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 [20]. Karena mobilenet dirancang untuk aplikasi mobile, maka arsitektur ini harus mampu berjalan dengan kemampuan komputasi yang seminim mungkin namun tetap dapat memberikan tingkat akurasi yang tinggi.





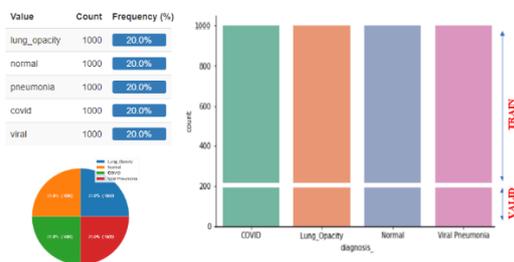
Gambar 7. Arsitektur mobilenet (atas) dan block modul linear bottleneck (bawah) [20]

Preparasi data dan tahap penelitian

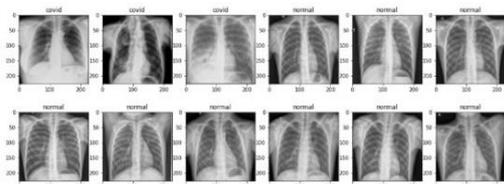
Penelitian ini menggunakan dataset input sebanyak 4000 *image*, yang bersumber dari repository kaggle.com [24] terbagi menjadi 4 kelas, yaitu:

- 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. (Grafik 2)



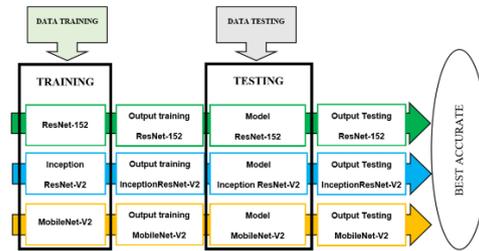
Grafik2. Pie dan histogram dataset



Gambar 8. Dataset Image Chest X-Ray

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 9)

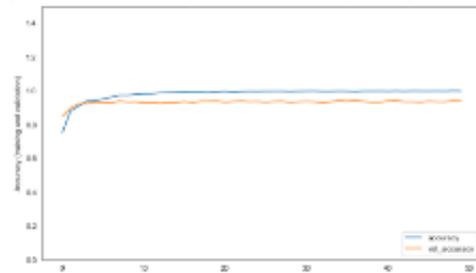


Gambar 9. Tahap penelitian

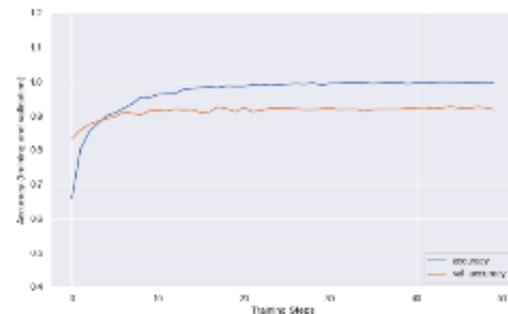
HASIL DAN PEMBAHASAN

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)

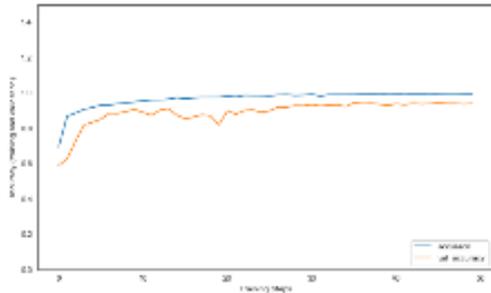
Dari table 1 terlihat prosentase untuk *train* dan *valid accurate* adalah sangat baik (>90%), namun untuk *train* dan *valid loss* masih terlihat cukup besar (>40%) dan perlu peningkatan kembali agar nilainya menjadi lebih kecil. Hasil dari proses *training* berupa model yang dapat dipergunakan untuk klasifikasi *image* tak berlabel. Untuk mengetahui hasil pengukuran yang lebih lengkap, maka dilakukan pengujian (*testing*) menggunakan data test berjumlah sama dengan data input yaitu 4000 *image* (1000 *image* tiap kelas).



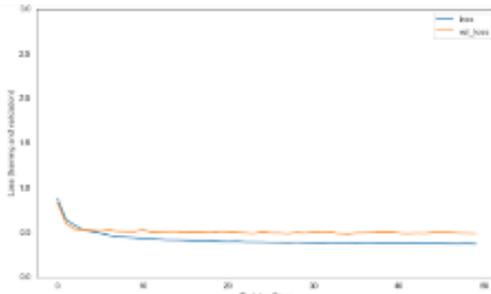
Grafik 3. Train Acc & Valid Acc ResNet-152



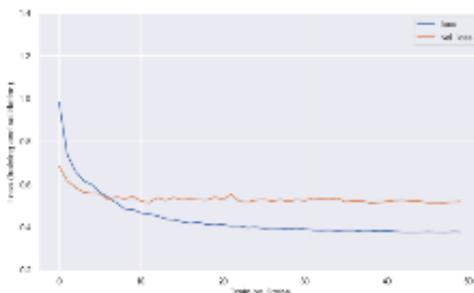
Grafik 4. Train Acc & Valid Acc InceptionResNet



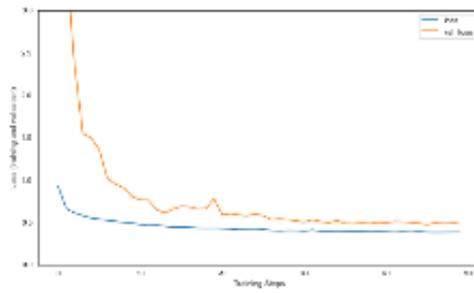
Grafik 5. Train Acc&Valid AccMobileNet-V2



Grafik 6. Train Loss&Valid LossResNet-152



Grafik 7. Train Loss&Valid LossInceptionResNet

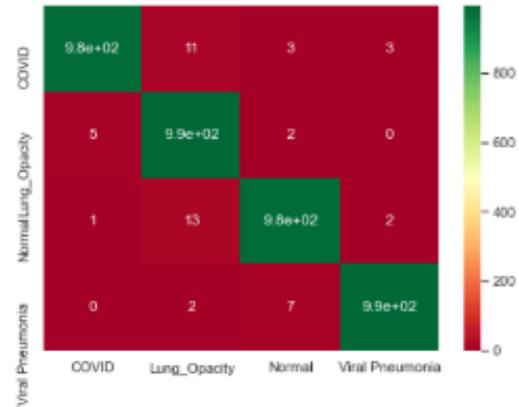


Grafik 8. Train Loss&Valid LossMobileNet-V2

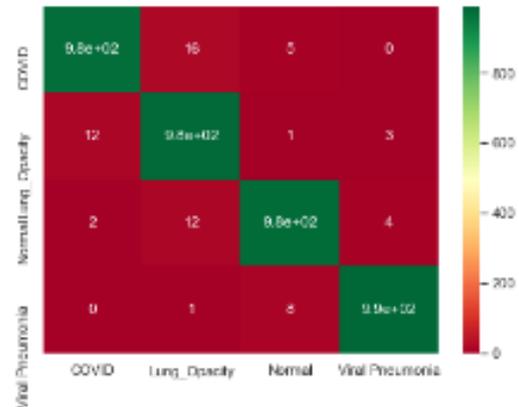
Tabel 1. Komparasi Hasil Training Tiga Arsitektur

		ResNet-152	InceptionResNet	MobileNet-V2	Ave
Train	Loss	0.3703	0.3769	0.3823	0.40
	Acc	0.9989	0.9958	0.9942	0.99
Valid	Loss	0.4873	0.52	0.4792	0.51
	Acc	0.9388	0.9175	0.9388	0.93

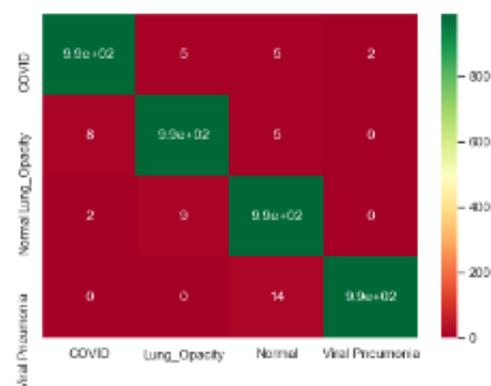
Program testing yang dijalankan menghasilkan output dalam bentuk *matrix confusion*.



Gambar 10. Hasil Testing dalam Confussion Matric ResNet-152



Gambar 11. Hasil Testing dalam Confussion MatricInceptionResNet



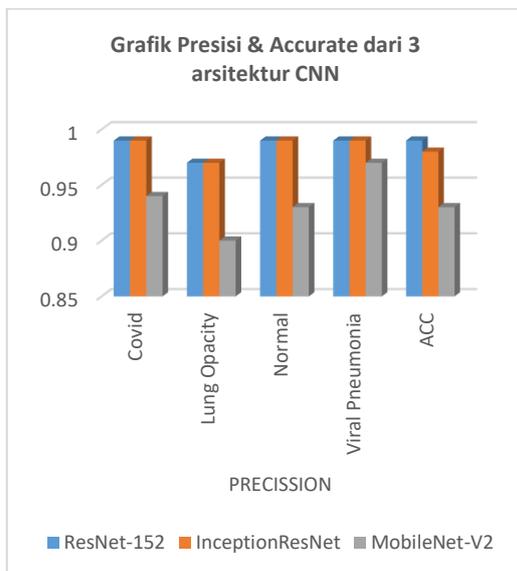
Gambar 12. Hasil Testing dalam Confussion MatricMobileNet-V2

Ringkasan hasil presisi testing dari tiga arsitektur dapat dilihat dalam tabel 2. Terlihat bahwa hasil akurasi dari arsitektur ResNet-152 mencapai 99%, sedangkan

akurasi dari arsitektur InceptionResNet mencapai 98%, dan akurasi hari MobileNet-V2 mencapai 93%. Dengan demikian optimasi dari 3 arsitektur CNN untuk klasifikasi image chest x-ray nilai optimal akurasi pada arsitektur ResNet-152.

Tabel 2. Hasil Presisi Testing

	ResNet-152	InceptionResNet	MobileNet-V2	
Precision	Covid	0.99	0.99	0.94
	Lung Opacity	0.97	0.97	0.90
	Normal	0.99	0.99	0.93
	Viral Pneumonia	0.99	0.99	0.97
	Accurate	0.99	0.98	0.93



Gambar 18. Grafik Presisi & Accurate dari 3 arsitektur CNN

PENUTUP

Simpulan yang dapat diambil dari hasil penelitian ini yaitu untuk memprediksi jenis penyakit covid dari dataset image Chest X-Ray menggunakan 3 arsitektur CNN adalah sangat baik dengan nilai akurasi lebih dari 90%. Hasil terbaik dari 3 arsitektur tersebut adalah ResNet dengan nilai akurasi 99% dan presisi tiap kelas lebih dari 95% yaitu: Covid (99%), Lung_Opacity (97%), Normal (99%), Viral_Pneumonia (99%).

DAFTAR PUSTAKA

- [1] worldometers, "Coronavirus Cases in India," Worldometers, 2021. [Online]. Available: <https://www.worldometers.info/coronavirus/country/india/>.
- [2] WHO Indonesia, "Coronavirus Disease 2019 (COVID-19)," 2021.
- [3] 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>.
- [4] covid19.go.id, "Data Sebaran," 2021. [Online]. Available: <https://covid19.go.id/>.
- [5] W. Hastomo and A. Satyo, "Kemampuan Long Short Term Memory Machine," vol. 4, no. September, pp. 229–236, 2020.
- [6] W. Karno, A. S. B., & Hastomo, "Optimalisasi Data Terbatas Prediksi Jangka Panjang Covid-19 Dengan Kombinasi Lstm Dan GRU," Pros. SeNTIK, vol. 4, no. September, pp. 181–191, 2020.
- [7] W. Hastomo, "Gesture Recognition For Pencak Silat Tapak Suci Real-Time Animation," vol. 2, pp. 91–102, 2020.
- [8] A. S. B. Karno, W. Hastomo, & Arif, D., and E. S. Moreta, "Optimasi Portofolio Dan Prediksi Cryptocurrency Menggunakan Deep Learning Dalam Bahasa Python," vol. 4, no. September, 2020.
- [9] W. Hastomo, A. Satyo, B. Karno, and N. Kalbuana, "Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia," 2021.
- [10] W. Hastomo and A. Satyo, "Long Short Term Memory Machine Learning Untuk Memprediksi Akurasi Nilai Tukar IDR Terhadap USD," vol. 3, 2019.
- [11] A. 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.
- [12] 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.
- [13] L. M. Rasdi Rere, M. I. Fanany, and A. M. Arymurthy, “Metaheuristic Algorithms for Convolution Neural Network,” *Comput. Intell. Neurosci.*, vol. 2016, 2016.
- [14] 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.
- [15] L. M. R. Rere, R. Dalam, and K. Baru, “Studi Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network,” vol. 3, 2019.
- [16] L. Alzubaidi et al., *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021.
- [17] B. Prijono, “Student Notes: Convolutional Neural Networks (CNN) Introduction,” *Indoml.com*. [Online]. Available: <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>.
- [18] 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.
- [19] V. Sangeetha and K. J. R. Prasad, “Deep residual learning for image recognition,” *Indian J. Chem. - Sect. B Org. Med. Chem.*, vol. 45, no. 8, pp. 1951–1954, 2006.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] N. Van Hieu and N. L. H. Hien, “Recognition of plant species using deep convolutional feature extraction,” *Int. J. Emerg. Technol.*, vol. 11, no. 3, pp. 904–910, 2020.
- [24] Corrochann, “COVID-19 Chest X-ray images,” *kaggle.com*, 2020. [Online]. Available: <https://www.kaggle.com/datasets?search=chest-xray+>.