



Arsitektur *Convolutional Neural Network InceptionResNet-V2* Untuk Pengelompokan *Pneumonia Chest X-Ray*

Indra Bakti¹, Mohamad Firdaus²

¹ Teknologi Informasi ITB Ahmad Dahlan, Jl. Ir H. Juanda No.77, Cireundeu, Kec. Ciputat Timur, Tangerang Selatan, Banten 15419

² Universitas Indraprasta PGRI Jl. Nangka Raya No.58 C, RW.5, Tj. Barat, Kec. Jagakarsa, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta 12530,

* Email Korespondensi: indra.itbad@gmail.com, mfirdausmum@gmail.com

INFO ARTIKEL	ABSTRAK
<p>Sejarah Artikel: Diterima Tgl 26/01/2023 Diperbaiki Tgl. 29/01/2023 Disetujui Tgl. 30/01/2023 Tersedia daring Tgl 31/01/2023</p>	<p>Dalam abad terakhir ini, khususnya metode <i>Convolution Neural Network</i> (CNN) pada penggunaan <i>machine learning</i> yang merupakan teknologi intelegensi artifisial atau <i>Artificial Intelligence</i> (AI) telah dapat dan sangat mampu membantu dunia medis (kedokteran). Melalui penelitian tindakan pada dataset gambar, CNN berhasil dan mampu menunjukkan klasifikasi atau pengelompokan berdasarkan karakteristik dan properti yang sama pada gambar yang tidak berlabel dengan akurasi lebih tinggi dan lebih cepat daripada metode pembelajaran mesin lainnya. Hal ini sangat berguna bagi dunia Kesehatan, khususnya dalam penggunaan <i>chest-x-ray</i> (rontgen dada) pada dunia kedokteran. Studi ini bertujuan untuk mengoptimalkan arsitektur CNN <i>InceptionResNet-V2</i>, untuk mengklasifikasikan penyakit Covid-19, dengan melatih 4000 dataset citra <i>x-ray</i> dada. Hasil uji akurasi dari <i>InceptionResNet-V2</i> menghasilkan 98%, dengan presisi tiap kelas arsitektur CNN <i>InceptionRestNet-V2</i> adalah Covid (99%), <i>Lung_Opacity</i> (97%), Normal (98%), <i>Viral_Pneumonia</i> (98%). Arsitektur CNN <i>InceptionRestNet</i> dapat membantu hasil <i>chest-x-ray</i> dengan cepat dan akurat.</p>
<p>e-ISSN 2961-9009 p-ISSN 2963-1289</p>	
<p>DOI https://doi.org/10.58290/jukomtek.v1i2.66</p>	<p>Kata Kunci: <i>InceptionResNet, Convolution Neral Network, Chest X-Ray, Pneumonia</i></p>
<p>©2022. Diterbitkan oleh Jurnal Komputer dan Teknologi (JUKOMTEK). Artikel ini memiliki akses terbuka di bawah lisensi CC BY (https://creativecommons.org/licenses/by/4.0/)</p>	

PENDAHULUAN

Negara Indonesia merupakan bagian dari dampak pandemi penyakit COVID-19 yang sedang berlangsung di seluruh dunia. Penyakit ini disebabkan oleh korona virus sindrom pernapasan akut berat 2 kasus ditemukan maret 2020(Y. D, 2020). Dan pada tanggal 23 Juni 2021 Pemerintah Indonesia melaporkan kasus terkonfirmasi Covid-19


mencapai 2.033.421 jiwa (WHO, 202AD). Hal ini berdampak pada kebijakan Pemerintah Hong Kong melarang seluruh penerbangan dari Indonesia. Larangan itu menyusul status Indonesia yang berubah menjadi negara A1 (*extremly high risk*)(Kompas, 2021).

Diagnosa covid-19 secara akurat dapat dilakukan dari foto rontgen dada (*image chest x-ray*), namun memerlukan para

medis dengan keahlian khusus untuk dapat membaca *data image* tersebut. Karena terbatasnya jumlah para medis ini, menjadikan waktu lama (1-2 minggu) untuk mendapatkan hasil diagnosa.

Metode *Convolution Neural Network* (CNN) yang adalah merupakan Teknologi intelegensi artifisial atau *Artificial Intelligence* (AI) dapat dan mampu memprediksi image *chest x-ray* terhadap penyakit covid-19. Penelitian ini bertujuan memperoleh hasil terbaik pada arsitektur CNN *InceptionResNet* untuk mendeteksi covid-19 dari image *chest x-ray*.

Pneumonia adalah salah satu penyakit yang sering kita dapatkan di dunia ini dan untuk mendiagnosisnya dibutuhkan keahlian tertentu. Dalam penelitian ini (pengelompokan *pneumonia Chest X-Ray*), penulis menggunakan arsitektur *deep learning Inception-ResNet-v2*.




Gambar 1. Sampel rontgen dada menunjukkan pasien sehat (a), *pneumonia* akibat infeksi bakteri (b), *pneumonia* akibat infeksi virus (c), dan *pneumonia* akibat kasus COVID-19 (d).

Untuk pengelompokan atau klasifikasi *pneumonia* dan membantu dokter dengan diagnosa mereka, maka solusi yang efektif adalah dengan menganalisis gambar rontgen dada (William *et al.*, 2018). Hal ini dapat dilihat pada gambar 1, penyebaran infeksi terlihat jelas melalui teknologi x-ray, terutama untuk kondisi parah seperti yang terkait dengan virus SARS-CoV-2. Untuk sepenuhnya mengeksplorasi informasi yang ditemukan dalam gambar tersebut, pendekatan pembelajaran mendalam sedang dieksplorasi karena mereka sudah dapat memperoleh kinerja yang signifikan di beberapa bidang medis yang heterogen (Minaee *et al.*, 2020; Avola *et al.*, 2021). Secara rinci, banyak solusi yang berfokus pada klasifikasi biner antara orang sehat dan pasien COVID-19 (Brunese *et al.*, 2020).

Untuk mengeksplorasi kemampuan klasifikasi *pneumonia* dari gambar rontgen dada, dengan perhatian khusus pada infeksi SARS-CoV-2, dilakukan eksperimen pada kumpulan data yang dirancang khusus untuk memuat data dari berbagai koleksi publik yang menangani tugas klasifikasi *pneumonia*. Perhatikan bahwa koleksi yang digabungkan memiliki dimensi rontgen dada yang

heterogen karena datanya berasal dari kelompok penelitian yang berbeda. Hal ini ditunjukkan pada Gambar 2. Untuk tiga kelas pertama, mereka diambil dari *pneumonia* Kaggle yang terkenal, dan dibagi menjadi set pelatihan, pengembangan, dan rangkaian tes yang berkesesuaian (Kermany *et al.*, 2018).




Gambar 2. Skema Subdivisi Dataset (kumpulan data).

Penelitian ini bertujuan untuk mendeteksi *Viral Pneumonia* dari image *chest x-ray* dengan Arsitektur *InceptionResNet-V2*. Dimana hasil penelitiannya dapat dilihat pada Tabel.3. Hasil Presisi Testing. Sedangkan untuk data set inputnya diperoleh dari <https://www.kaggle.com>. Kita ketahui penyakit *pneumonia* adalah penyakit infeksi yang disebabkan oleh bakteri atau jamur patogen dan virus pada saluran pernapasan akut. Infeksi ini memberi dampak pada satu atau kedua paru-paru kita dan dapat mengakibatkan efek ringan sampai mengancam jiwa segala usia. Penyakit menular ini menyebabkan kematian terbesar di dunia pada anak-anak; dimana 15% kematian anak-anak tahun 2017, data dari statistik Organisasi Kesehatan Dunia (WHO) dan di antara sumber yang mungkin adalah bakteri dan virus (penyebab infeksi *pneumonia*)(Smith *et al.*, 2014).

LANDASAN TEORI

Era teknologi saat ini hampir semuanya melibatkan *artificial intelligence* (AI) dan *deep learning* (DL) adalah teknik yang paling banyak dipergunakan dalam pendekatan komputasi dalam bidang *Machine Learning* (ML). Banyak aplikasi yang dibentuk dengan melibatkan ML(Hastomo and Karno, 2020; Karno, Hastomo and Wardhana, 2020). Jenis DL yang paling luas pemanfaatannya dalam kehidupan manusia adalah *Convolutional Neural Network* (CNN) (Rasdi Rere, Fanany and Arymurthy, 2016)(Ayumi *et al.*, 2016; Rere, Usna and Soegijanto, 2019).

Lapisan yang dalam dibandingkan dengan ML lainnya, menjadikan metode ini masuk dalam kategori DL. Kemampuan untuk dapat membedakan objek *image*, maka teknik ini lebih dikenal dengan CNN (Gambar 3). Beberapa proses dan istilah dalam CNN akan dijelaskan secara singkat pada sub bagian ini.

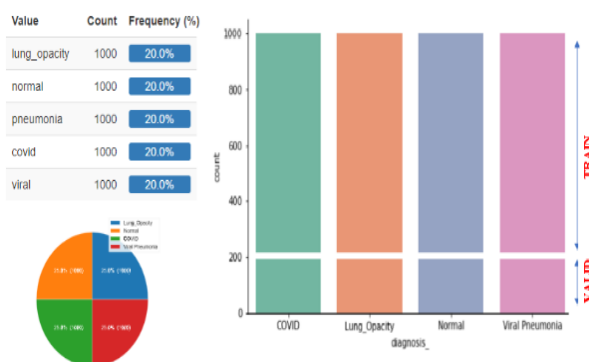


Gambar 3. Klasifikasi CNN dalam AI


METODE PENELITIAN

Penelitian ini menggunakan *dataset input* sebanyak 4000 *image*, terbagi menjadi 4 kelas, yaitu:
0 – Normal, sebanyak 1.000 image (25%)
1 – *Viral Pneumonia*, sebanyak 1.000 image (25%)
2 – *Lung Opacity*, sebanyak 1.000 image (25%)
3 – Covid, sebanyak 1.000 image (25%)

Dari 1000 image data tiap kelas terbagi 80% (800 image) untuk data training dan 20% (200 image) untuk validasi data (Gambar 4 dan Gambar 5).

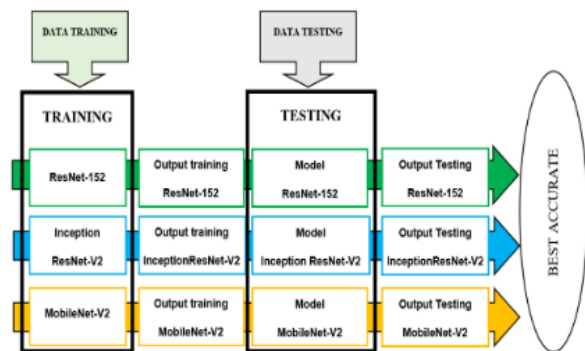


Gambar 4. Pie dan Histogram Dataset



Gambar 5. Dataset Image Chest X-Ray


Dataset input (data train dan validasi) dipergunakan sebagai data latih untuk arsitektur CNN InceptionResNet 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 6)



Gambar 6. Tahap penelitian

2.1. Convolutional Neural Network


Pemikiran awal CNN adalah jaringan saraf (neuron) di manusia dan binatang (Alzubaidi *et al.*, 2021). 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*. *Fully Connected* bertujuan untuk mengklasifikasikan *image* dari suatu label tertentu. (Gambar 7).



Gambar 7. A Convolution Layer

```

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



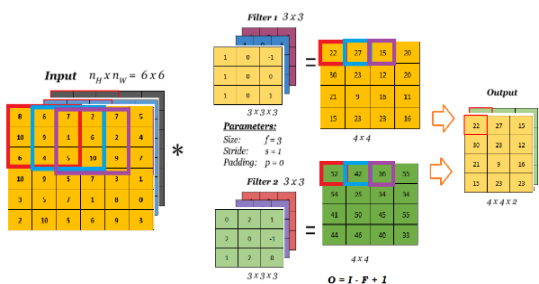
Gambar 8. Proses konvolusi (atas) yang merupakan bagian dari lapisan CNN secara keseluruhan (bawah) (B. Priyono, 2018)

```

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())
    
```

2.1.1. Proses konvolusi

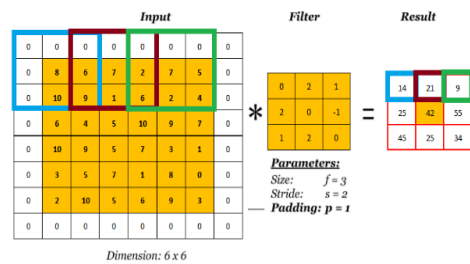
Proses konvolusi merupakan perhitungan *dot product* antara matrik input dan matrik filter. Matrik filter adalah matrik segi empat (*height=width*) yang merupakan kumpulan nilai bobot (*weight*), kadang juga disebut juga sebagai matrik *kernel*. Ukuran *height* dan *width* selalu lebih kecil dari input, tapi nilai *depth (channel)* sama dengan *depth* input. Dalam proses konvolusi umumnya menggunakan lebih dari satu jenis matrik *kernel* (filter 1, filter 2, dan seterusnya). Ukuran matrik output untuk baris dan kolom dapat digunakan ketentuan $O = I - F + 1$. (Gambar 9).



Gambar 9. Detail proses konvolusi

2.1.2. Proses stride

Proses *stride* sebenarnya adalah bagian dari proses konvolusi itu sendiri. Matrik filter akan melakukan scanning terhadap matrik input, dengan cara melakukan konvolusi kedua matrik tersebut sesuai ukuran matrik filter. Setelah proses pertama selesai dilanjutkan dengan proses konvolusi kedua dengan menggerakkan matrik input (matrik input ke dua) yang akan di konvolusi dengan matrik filter. Pergeseran matrik input pertama dan kedua adalah sesuai dengan nilai *stride* yang ditentukan sebagai parameter dalam tiap lapisan. Proses ini diulang untuk konvolusi selanjutnya, sehingga dihasilkan matrik dengan ukuran yang lebih kecil. (Gambar 10).




Gambar 10. Stride dan Padding

2.1.3. Proses padding

Padding adalah proses penambahan nilai yang besar sama disetiap sisi image input (biasanya nilai 0 atau satu). Walaupun matrik input menjadi berukuran lebih besar dari semula, namun dalam proses konvolusi akan tetap lebih kecil dari matrik input aslinya. Tujuan dari *padding* adalah memberikan batasan yang lebih jelas dari suatu *image*, sehingga proses dapat menjadi lebih focus. *Padding* kadang juga dipergunakan untuk menyesuaikan ukuran matrik output dengan cara menambah nilai di tiap sisi *image* sehingga sesuai dengan matrik input yang akan digunakan pada lapisan *convolutional* selanjutnya. (Gambar 10).

2.1.4. Pooling

Sebenarnya proses *pooling* identik dengan pengambilan sample data dalam statistik, bedanya dalam pooling tidak ada informasi hilang. Pooling bertujuan untuk memperkecil ukuran matrik agar perhitungan yang dilakukan mesin menjadi lebih cepat. Terdapat banyak jenis pooling, tapi yang umum dipergunakan adalah *max pooling* dan *average pooling*. *Max pooling* adalah mengambil nilai terbesar dalam ukuran matrik tertentu, sedangkan *average pooling* adalah mengambil nilai rata-rata dalam ukuran matrik tertentu. (Gambar 11).



Gambar 11. Proses Pooling

2.1.5. Activation Function

Fungsi aktivasi diberikan setelah proses *pooling*, tujuannya agar nilai yang dihasilkan berada dalam rentang nilai tertentu (biasanya berkisar 0 sampai 1) dan juga berfungsi mengambil keputusan untuk mengambil hasil yang sesuai dan menghilangkan hasil yang tidak diinginkan (kurang baik), memetakan input ke output yang tidak linier, memberikan kemampuan belajar yang lebih kompleks. Fungsi aktivasi juga memiliki kemampuan untuk dapat membedakan *feature-feature* yang sangat penting (Ayumi *et al.*, 2016).


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

Copyright © Sebastian Raschka 2016 (http://sebastianraschka.com)

Gambar 12. Jenis Fungsi Aktivasi (Sebastian Raschka, 2020)

2.1.6. Fully Connected Layer (FC)

Proses ini adalah akhir dari CNN, yang dinamakan *fully connected* karena semua *neuron* (node) terhubung dengan neuron di lapisan sebelum dan sesudahnya. Dimana fungsinya adalah sebagai klasifikasi, proses ini secara teknis ini tidak lain adalah metode lapisan *neural network conventional* (*feed forward neural network*) (Alzubaidi *et al.*, 2021), untuk jelasnya dapat dilihat pada gambar 13.




Gambar 13. Jaringan fully connected (FC)

2.2. Arsitektur CNN

Dari kompetisi yang dilakukan oleh ILSVRC yakni *ImageNet Large Scale Visual Recognition Challenge*, terdapat banyak arsitektur CNN yang sudah diciptakan sebagai upaya meningkatkan akurasi melalui pengujian input dataset tertentu yang dijadikan sebagai standar (MNIST (Rasdi Rere, Fanany and Arymurthy, 2016), *imagenet*, *coconut* dll) (Gambar 10). 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 (Bianco *et al.*, 2018).

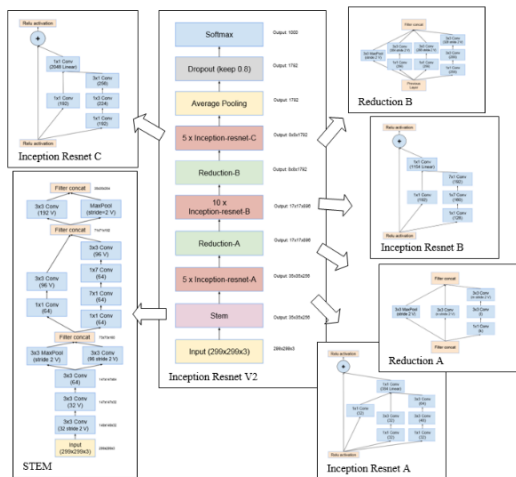
Pada penelitian ini akan dicoba arsitektur CNN yang mampu dikerjakan oleh komputer yakni arsitektur CNN *InceptionResNet*, dengan sedikit melakukan penyesuaian agar didapatkan hasil yang diharapkan. Arsitektur CNN ini akan melakukan proses training dan pengujian dengan menggunakan *data set image chest x-ray* untuk mendeteksi keberadaan jenis penyakit covid-19. Untuk data set image penelitian ini didapatkan atau diperoleh dari <https://www.kaggle.com/code/ernestomaisuls/covid-19-x-ray-modified-xception/data>.




Gambar 14. Komparasi akurasi arsitektur CNN berdasarkan ILSVRC (Bianco *et al.*, 2018)

2.2.1. InceptionResNet-V2

Sebagai upaya pengembangan CNN, Szegedy (2014) memperkenalkan Inception dalam papernya yang berjudul “Going Deeper with Convolution” (Szegedy *et al.*, 2015). Dimana Convolution ini merupakan tindakan ekstraksi image untuk mendapatkan model dalam bentuk matrik kernel. Pada proses ini dilakukan filterisasi yang bergeser dengan “stride value” tertentu pada suatu input image. Atau suatu proses untuk melihat nilai parameter yang menentukan berapa banyak jumlah pergeseran filter pada suatu input image (Gambar 15 dan Gambar 16). Selanjutnya hasil dari convolution menjadi input bagian fully connected untuk proses klasifikasi (Szegedy *et al.*, 2017). Hal ini bertujuan untuk mendapatkan jaringan yang lebih handal dan meningkatkan tingkat akurasi klasifikasi yang dihasilkan dengan menggunakan arsitektur *InceptionResNet* ini.



Gambar 15. Blok modul Inception Resnet-V2



Gambar 16. Diagram keseluruhan Inception Resnet V2) (Van Hieu and Hien, 2020)

HASIL DAN PEMBAHASAN

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

Tabel 1. Hasil Training

		InceptionResNet
TRAIN	Loss	0.3769
	Acc	0.9958
VALID	Loss	0.52
	Acc	0.9175
History	Train Acc, Val Acc, Train Loss, Val Loss	
Grafik	Train Acc, Val Acc	
	Train Loss, Val Loss	

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

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). Program *testing* yang dijalankan menghasilkan output dalam bentuk matrik *confussion* dan *classification report*. Hasil output testing ini dikumpulkan dalam table sebagai berikut : (Tabel. 2)

Tabel 2. Hasil Testing

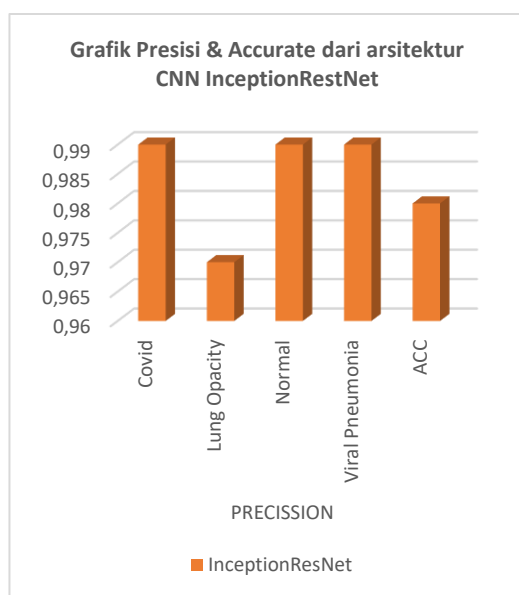
		InceptionResNet																														
Confusion Matric		<pre>from sklearn.metrics import confusion_matrix, accuracy_score import seaborn as sns print(accuracy_score(y_test, y_pred)) confusion_matrix(y_test, y_pred)</pre>																														
Classification Report		<pre>!CLASSIFICATION REPORT from sklearn.metrics import classification_report print(classification_report(y_test, y_prediction, target_names=class_names))</pre> <table border="1"> <thead> <tr> <th></th> <th>precision</th> <th>recall</th> <th>f1-score</th> <th>support</th> </tr> </thead> <tbody> <tr> <td>COVID</td> <td>0.99</td> <td>0.98</td> <td>0.98</td> <td>1000</td> </tr> <tr> <td>Lung_Cancer</td> <td>0.97</td> <td>0.98</td> <td>0.98</td> <td>1000</td> </tr> <tr> <td>Normal</td> <td>0.99</td> <td>0.98</td> <td>0.98</td> <td>1000</td> </tr> <tr> <td>Viral_Pneumonia</td> <td>0.99</td> <td>0.99</td> <td>0.99</td> <td>1000</td> </tr> <tr> <td>accuracy</td> <td colspan="4">0.98 4000</td> </tr> </tbody> </table>		precision	recall	f1-score	support	COVID	0.99	0.98	0.98	1000	Lung_Cancer	0.97	0.98	0.98	1000	Normal	0.99	0.98	0.98	1000	Viral_Pneumonia	0.99	0.99	0.99	1000	accuracy	0.98 4000			
	precision	recall	f1-score	support																												
COVID	0.99	0.98	0.98	1000																												
Lung_Cancer	0.97	0.98	0.98	1000																												
Normal	0.99	0.98	0.98	1000																												
Viral_Pneumonia	0.99	0.99	0.99	1000																												
accuracy	0.98 4000																															

Agar lebih detail dan terlihat jelas, nilai *precision classification report* dari Table 2, dirangkum dalam

table yakni dapat dilihat pada Tabel. 3 dan untuk grafik dapat dilihat pada gambar 17 dibawah ini :

Tabel 3. Hasil Presisi Testing

		<i>InceptionResNet</i>
PRECISION	<i>Covid</i>	0.99
	<i>Lung Opacity</i>	0.97
	<i>Normal</i>	0.98
	<i>Viral Pneumonia</i>	0.98
Accurate		0.98



Gambar 17. Grafik Presisi & Accurate dari arsitektur CNN InceptionRestNet

KESIMPULAN

Hasil dari penelitian Pengelompokan *Pneumonia Chest X-Ray* ini yakni sebagai berikut :

- Hasil penelitian untuk memprediksi jenis penyakit *Viral_Pneumonia* dari data foto rontgen dada (*image Chest X Ray*) dengan menggunakan arsitektur CNN *InceptionRestNet* adalah sangat baik yakni dengan nilai akurasi lebih dari 95% yakni 99%. Dan untuk Hasil arsitektur CNN *InceptionResNet-V2* adalah dengan nilai akurasi 98% dan presisi untuk tiap kelasnya lebih dari 95% yaitu: Covid (99%), *Lung Opacity* (97%), Normal (98%), *Viral Pneumonia* (98%).
- Penerapan teknologi intelegensi artifisial (AI) dengan metode CNN *InceptionRest Net* di dalam dunia kedokteran (medis) adalah sangat diperlukan untuk membantu

meringankan kerja para medis dan membantu masyarakat.

- Metode *Convolution Neural Network* (CNN) yang menggunakan arsitektur CNN *InceptionRestNet-V2* adalah merupakan teknologi intelegensi artifisial atau Artificial Intelligence (AI) dapat dan mampu memprediksi *image chest x-ray* terhadap penyakit covid-19.
- Diagnosa covid-19, khususnya pada *Pneumonia* secara akurat dapat dilakukan dari foto rontgen dada (*image chest x-ray*), namun memerlukan para medis dengan keahlian khusus untuk dapat membaca data image tersebut. Karena terbatasnya jumlah para medis ini, menjadikan waktu lama (1-2 minggu) untuk mendapatkan hasil diagnosa.

DAFTAR PUSTAKA

- Alzubaidi, L. *et al.* (2021) *Review of Deep Learning Concepts, CNN Architectures, Challenges, Applications, Future Directions*, *Journal of Big Data*. Springer International Publishing. Available at: <https://doi.org/10.1186/s40537-021-00444-8>.
- Avola, D. *et al.* (2021) 'Ultrasound medical imaging techniques: a survey', *ACM Computing Surveys (CSUR)*, 54(3), pp. 1–38.
- Ayumi, V. *et al.* (2016) 'Optimization of convolutional neural network using microcanonical annealing algorithm', in *2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, pp. 506–511.
- B. Priyono (2018) *Student Notes: Convolutional Neural Networks (CNN) Introduction*, *indoml*. Available at: <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>.
- Bianco, S. *et al.* (2018) 'Benchmark analysis of Representative Deep Neural Network Architectures', *IEEE Access*, 06, pp. 64270–64277. Available at: <https://doi.org/10.1109/ACCESS.2018.2877890>.
- Brunese, L. *et al.* (2020) 'Explainable deep learning for pulmonary disease and coronavirus COVID-19 detection from X-rays', *Computer Methods and Programs in Biomedicine*, 196, p. 105608.
- Hastomo, W. and Karno, A.S.B. (2020) 'Kemampuan Long Short Term Memory Machine Learning Dalam Proyeksi Saham Bank Bri Tbk', *Prosiding SeNTIK*, 4(September), pp. 229–236. Available at:

- <https://ejournal.jak-stik.ac.id/index.php/sentik/article/view/302%0Ahttps://ejournal.jak-stik.ac.id/index.php/sentik/article/download/302/162>.
- Van Hieu, N. and Hien, N.L.H. (2020) 'Recognition of plant species using deep convolutional feature extraction', *International Journal on Emerging Technologies*, 11(3), pp. 904–910.
- Karno, A.S.B., Hastomo, W. and Wardhana, I.S.K. (2020) 'Prediksi Jangka Panjang Covid-19 Indonesia Menggunakan Deep Learning Long Term', *Semin. Nas. Teknol. Inf. dan Komun.*, pp. 483–490.
- Kernany, D.S. *et al.* (2018) 'Identifying medical diagnoses and treatable diseases by image-based deep learning', *cell*, 172(5), pp. 1122–1131.
- Kompas (2021) *Selain Hong Kong, Sejumlah Negara Ini Masih Melarang Masuk WNI*, *Kompas.com*. Available at: <https://www.kompas.com/tren/read/2021/06/25/103000965/selain-hong-kong-sejumlah-negara-ini-masih-melarang-masuk-wni?page=all>.
- Minaee, S. *et al.* (2020) 'Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning', *Medical image analysis*, 65, p. 101794.
- Rasdi Rere, L.M., Fanany, M.I. and Arymurthy, A.M. (2016) 'Metaheuristic Algorithms for Convolution Neural Network', *Computational Intelligence and Neuroscience*, 2016. Available at: <https://doi.org/10.1155/2016/1537325>.
- Rere, L.M.R., Usna, S. and Soegijanto, D. (2019) 'Studi Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network', *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, 3.
- Sebastian Raschka (2020) *Activation Functions for Artificial Neural Networks*, *Github.Io*. Available at: http://rasbt.github.io/mlxtend/user_guide/general_concepts/activation-functions/.
- Smith, S.B. *et al.* (2014) 'Trends in pathogens among patients hospitalized for pneumonia from 1993 to 2011', *JAMA internal medicine*, 174(11), pp. 1837–1839.
- Szegedy, C. *et al.* (2015) 'Going deeper with convolutions', in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 1–9. Available at: <https://doi.org/10.1109/CVPR.2015.7298594>.
- Szegedy, C. *et al.* (2017) 'Inception-v4, inception-resnet and the impact of residual connections on learning', in *Proceedings of the AAAI conference on artificial intelligence*.
- WHO (2020AD) *WHO Coronavirus Disease (COVID-19) Dashboard | WHO Coronavirus Disease (COVID-19) Dashboard*, *Who.int*. Available at: https://covid19.who.int/?gclid=CjwKCAjwnK36BRBV EiwAsMT8WJ3y00_BUzvrLsvbl3uthuoTH_Occ45gyEUbpYRyEqAzll3aZB6TYxoCcM0QAvD_BwE.
- William, W. *et al.* (2018) 'A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images', *Computer methods and programs in biomedicine*, 164, pp. 15–22.
- Y. D, D. (2020) *2 Maret 2020 Kasus Corona Pertama di Indonesia Diumumkan Tahun Lalu.*, *Tirto.id*. Available at: <https://tirto.id/2-maret-2020-kasus-corona-pertama-di-indonesia-diumumkan-tahun-lalu-gaKw>.