

DIAGNOSA COVID-19 CHEST X-RAY DENGAN CONVOLUTION NEURAL NETWORK ARSITEKTUR RESNET-152

Widi Hastomo¹ dan Adhitio Satyo Bayangkari Karno²

Fakultas Ekonomi Digital, ITB Ahmad Dahlan Jakarta¹, Fakultas Teknologi Informasi, Universitas Gunadarma²

ABSTRACT

The availability of medical aids in adequate quantities is very much needed to assist the work of the medical staff in dealing with the very large number of Covid patients. Artificial Intelligence (AI) with the Deep Learning (DL) method, especially the Convolution Neural Network (CNN), is able to diagnose Chest X-ray images generated by the Computer Tomography Scanner (C.T. Scan) against certain diseases (Covid). Resnet Version-152 architecture was used in this study to train a dataset of 10.300 images, consisting of 4 classifications namely covid, normal, lung opacity with 3,000 images each and viral pneumonia 1,000 images. The results of the study with 50 epoch training obtained very good values for the accuracy of training and validation of 95.5% and 91.8%, respectively. The test with 10.300 image dataset obtained 98% accuracy testing, with the precision of each class being Covid (99%), Lung_Opacity (99%), Normal (98%) and Viral pneumonia (98%).

Article History

Received 2021-07-16
Revised 2021-07-23
Accepted 2021-07-31

Key words

Covid-19, Convolution Neural Network, Chest x-ray

ABSTRAK

Ketersediaan alat bantu medis dalam jumlah memadai sangat diperlukan untuk membantu kerja para medis dalam menangani jumlah pasien Covid-19 yang sangat banyak. *Artificial Intelligence* (AI) dengan metode *Deep Learning* (DL), khususnya *Convolution Neural Network* (CNN), mampu mendiagnosa image *Chest X-Ray* yang dihasilkan oleh alat *Computer Tomography Scanner* (CT Scan) terhadap penyakit tertentu (Covid). Arsitektur Resnet-152 dipergunakan dalam penelitian ini untuk melakukan training dataset 10.300 image, terdiri dari 4 klasifikasi yaitu covid, normal, lung opacity masing-masing dengan jumlah data 3.000 image dan viral pneumonia 1.300 image. Hasil penelitian dengan training 50 epoch diperoleh nilai yang sangat baik untuk akurasi training dan validasi sebesar 95,5% dan 91,8%. Uji testing dengan jumlah data uji 10.300 image diperoleh akurasi testing 99%, dengan presisi tiap kelas adalah Covid (99%), Lung Opacity (99%), Normal (98%) dan Viral Pneumonia (98%).

PENDAHULUAN

Lebih dari satu tahun kita telah melalui pandemi Covid-19, jika merujuk informasi dari ourworldindata.org dalam tiga bulan terakhir ini, kasus kematian di Indonesia yang diakibatkan oleh Covid-19 mengalami kenaikan sebesar 101% [1]. Melihat jumlah kenaikan yang signifikan kecil kemungkinan pandemi ini akan segera berakhir. Banyak peneliti telah berupaya dalam mengurangi pencegahan penularan Covid-19 [2]–[9], [10]. Untuk lebih efektif mengontrol penyebaran Covid-19 [11] dan mengobati pasien serta mengurangi angka kematian, citra medis dapat memiliki peran yang sangat penting [12]. Saat ini praktek uji klinis, radiografi *chest x-ray* (CXR) dan *computed tomography* (CT) adalah dua modalitas pencitraan untuk mendeteksi Covid-19, untuk menilai keparahannya, dan memantau prognosinya (respon terhadap pengobatan) [13].

Meski CT bisa mencapai sensitivitas deteksi yang lebih tinggi, namun radiografi rontgen dada/CXR lebih banyak dan biasa digunakan dalam praktek klinis karena kelebihannya yaitu; termasuk dalam kategori biaya rendah, dosis radiasi rendah, mudah dioperasikan dan aksesibilitas lebih luas di rumah sakit umum [14]. Namun, pneumonia bisa menjadi penyebab dari berbagai jenis virus dan bakteri. Hal ini menjadi tantangan dan memerlukan waktu lebih banyak bagi ahli radiologi di komunitas rumah sakit untuk membaca gambar *rontgen* dada dalam jumlah besar serta untuk mendeteksi pneumonia yang terinfeksi Covid-19 dan membedakannya dari yang lain, pneumonia yang tidak terinfeksi Covid-19 yang didapat dari masyarakat. Karena ada banyak kesamaan antara

pneumonia yang terinfeksi Covid-19 dan jenis virus atau bakteri lainnya. Kondisi seperti ini menjadi tantangan klinis yang dihadapi oleh ahli radiologi dalam masa pandemi ini [15].

Untuk mengatasi tantangan ini, pengembangan deteksi dengan bantuan komputasi berdasarkan pemrosesan citra medis dan pembelajaran mesin telah menarik minat penelitian ini, yang bertujuan untuk mendiagnosa karakteristik penyakit secara otomatis dan menyediakan alat pendukung pengambilan keputusan yang berharga bagi ahli radiologi untuk deteksi dan diagnosis yang lebih akurat atau efisien dari pneumonia yang terinfeksi Covid-19. *Convolution Neural Network* (CNN) dengan arsitektur ResNet-152 menjadi pilihan karena dapat menghasilkan akurasi yang baik [16], cukup memerlukan komputasi yang minimum serta dapat diaplikasikan oleh komputer sederhana, hal ini berarti setiap rumah sakit dan komunitas tidak perlu melakukan investasi yang besar dalam penerapannya.

TINJAUAN PUSTAKA

Prinsip kerja CNN dapat digambarkan dengan dua langkah. Pertama, jaringan dilatih melalui label yang diberikan dataset dan fitur multi-skala yang diekstraksi. Kedua, berdasarkan fitur yang diekstraksi pada langkah pertama, dilakukan klasifikasi [17]. CNN terdiri dari beberapa komponen penting, antara lain convolutional layer, fungsi aktivasi, pooling layer dan fully connected layer. CNN sederhana biasanya terdiri dari beberapa lapisan, sementara beberapa model CNN yang sangat dalam dapat mencakup ratusan lapisan. Misalnya, satu versi ResNet populer saat ini terdiri dari 152 lapisan [16].

Lapisan convolutional adalah komponen penting dari CNN, dan neuron di lapisan convolutional sensitif terhadap setiap bagian kecil dari input gambar. Dalam terminologi CNN, parameter pertama dari konvolusi biasanya disebut input, parameter kedua disebut fungsi kernel, dan output disebut peta fitur, ditunjukkan dalam persamaan (1), di mana x adalah input, ω adalah kernel fungsi, $s(t)$ menunjukkan peta fitur keluaran. Definisi operasi konvolusi dua dimensi (2D) ditunjukkan pada persamaan (2), di mana I adalah input, K menunjukkan kernel 2D fungsi [18].

$$s(t) = (x * \omega) * (t) = \sum_{a=-\infty}^{\infty} x(a)\omega(t - a) \quad (1)$$

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (2)$$

Pemilihan fungsi aktivasi untuk CNN sangat penting. Saat ini, *Rectified Linear Unit* (ReLU) adalah fungsi aktivasi pilihan [19], yang didefinisikan sebagai berikut:


$$f(x) = \max(0, x) \quad (3)$$

Lapisan penyatuan dapat mengurangi biaya komputasi dengan menghitung karakteristik statistik keseluruhan dari wilayah persegi panjang yang berdekatan dari suatu lokasi untuk menggantikan output dari lapisan konvolusi pada daerah tersebut [2]. Misalnya, lapisan penyatuan maksimal, jenis layer penyatuan yang paling umum digunakan, menghitung nilai maksimum daerah persegi panjang yang berdekatan. Kecuali *max-pooling*, ada banyak pooling layer lainnya, seperti *average-pooling* dan *L2-norm pooling* [20].


Lapisan terakhir CNN adalah lapisan yang terhubung penuh, dimana setiap neuron dalam lapisan terhubung ke setiap neuron di lapisan berikutnya [18]. Output dari lapisan sebelumnya bisa dikirim ke lapisan yang terhubung penuh sebagai input, dan probabilitas skor untuk setiap kelas di mana gambar input dapat dihitung. Kelas dengan nilai tertinggi adalah hasil klasifikasi akhir dari citra masukan. Singkatnya, lapisan yang sepenuhnya terhubung menggabungkan fitur gambar yang paling menonjol untuk menyimpulkan kategori gambar [21].

ResNet-152 memperkenalkan konsep pembelajaran residual di mana pengurangan fitur dipelajari dari layer input dengan menggunakan koneksi pintasan (secara langsung menghubungkan input dari (n) layer ke beberapa $(n+x)$ layer, yang ditampilkan pada panah melengkung). Telah terbukti bahwa pembelajaran residual dapat meningkatkan kinerja pelatihan model, terutama ketika model memiliki jaringan yang dalam dengan lebih dari 20 layer, serta juga berkisar pada masalah

penurunan akurasi dalam jaringan yang dalam [16]. Arsitektur jaringan Resnet-152 terlihat pada gambar 1, jaringan Resnet-152 mencapai hasil pelatihan yang lebih baik, hal tersebut linier dengan validasi error yang lebih rendah dari arsitektur lainnya, seperti terlihat pada gambar 2.



Gambar 1. Arsitektur Resnet-152 [22].





Gambar 2. Validasi error 3 arsitektur CNN [16].

METODE


Dataset yang digunakan dalam penelitian ini bersumber dari kaggle.com [23], jumlah dataset yaitu 10.300 image chest x-ray. Secara klinis setiap image chest x-ray di klasifikasikan ke dalam empat kelas kelas [24] dengan jumlah dataset tiap kelas terlihat dalam Gambar 3:

0 – Normal	3.000 (29.1%)
1 – Viral Pneumonia	1.300 (12%)
2 – Lung_Opacity	3.000 (29.1%)
3 – Covid	3.000 (29.1%)

Value	Count	Frequency (%)
covid	3000	29.1%
normal	3000	29.1%
lung_opacity	3000	29.1%
viral	1300	12.6%




Gambar 3. Pie dan histogram dataset



Gambar 4. Dataset *Image Chest X-Ray*

Pembagian dataset menjadi 4 kategori yaitu Normal, Viral Pneumonia, Lung Opacity dan Covid. Pada gambar 4 yaitu dataset *image chest x-ray*. Data tersebut terdiri dari empat kelas, yakni; (a) 3000 *images* Covid-19, (b) 3000 *images* normal, (c) 3000 *images* lung opacity, (d) 1300 *images* viral pneumonia. Dari jumlah data *images* sejumlah 20% digunakan untuk data *testing*, sisanya untuk data *training*. Detail skema penelitian yang diusulkan seperti terlihat dalam Gambar 5.



Gambar 5. Skema Penelitian

Semua gambar sampel memiliki berbagai ukuran. Oleh karena itu, gambar-gambar itu ada yang diubah ukurannya menjadi 224×224 piksel. Normalisasi data dilakukan untuk pembelajaran sistem yang lebih baik serta untuk mencegah *overfitting* dan memudahkan generalisasi. Dataset dipartisi menjadi tiga set berbeda: set pelatihan, set validasi, dan set pengujian. Dengan set pelatihan dan validasi, model CNN yang diusulkan dilatih. Eksperimen dijalankan hingga epoch yang berbeda seperti 50, 60, dan 100. Setelah menjalankan jaringan selama 50 epoch, akurasi jaringan mulai jenuh. Dengan 50 epoch, model mencapai akurasi pelatihan dan validasi yang diharapkan.

Fully connected layer (FCL) dari model dipilih untuk mengekstrak fitur. Fitur vektor diekstraksi dari setiap gambar pelatihan dengan lapisan ini. Fitur vektor dari semua gambar ini dimasukkan ke dalam empat pengklasifikasi arsitektur ResNet-152. Untuk menyesuaikan hyperparameter pengklasifikasi yang terbaik. Terakhir, semua pengklasifikasi ResNet-152 digabungkan untuk mengembangkan ansambel pengklasifikasi, yang memprediksi label kelas berdasarkan suara mayoritas pengklasifikasi ResNet-152. Kinerja sistem yang diusulkan dievaluasi dalam hal confusion matrix, presisi, akurasi, dan skor F1. Dengan demikian, dataset siap untuk dimasukkan ke dalam jaringan CNN dan untuk melatih model.


HASIL DAN PEMBAHASAN

Hasil eksperimen dengan jumlah data 10.300 image dan melakukan 50 epoch dengan memperoleh nilai akurasi training dan validasi sangat baik yaitu masing 99,9% dan 93%. (Gambar 6). Terlihat grafik akurasi dan grafik *loss* sudah tidak mengalami banyak perubahan setelah training 50 epoch (Gambar 7 dan 8).


```
steps_per_epoch = train_generator.samples // train_generator.batch_size
validation_steps = valid_generator.samples // valid_generator.batch_size
hist = model.fit(
    train_generator,
    epochs=epochs, steps_per_epoch=steps_per_epoch,
    validation_data=valid_generator,
    validation_steps=validation_steps).history
```

```
257/257 [=====] - 1076s 4s/step - loss: 0.3669 - accuracy: 0.9984 - val_loss: 0.5251 - val_accuracy: 0.9224
Epoch 45/50
257/257 [=====] - 1090s 4s/step - loss: 0.3690 - accuracy: 0.9970 - val_loss: 0.5137 - val_accuracy: 0.9287
Epoch 46/50
257/257 [=====] - 1092s 4s/step - loss: 0.3691 - accuracy: 0.9968 - val_loss: 0.5213 - val_accuracy: 0.9229
Epoch 47/50
257/257 [=====] - 1090s 4s/step - loss: 0.3715 - accuracy: 0.9959 - val_loss: 0.5136 - val_accuracy: 0.9272
Epoch 48/50
257/257 [=====] - 1094s 4s/step - loss: 0.3693 - accuracy: 0.9958 - val_loss: 0.5099 - val_accuracy: 0.9302
Epoch 49/50
257/257 [=====] - 1090s 4s/step - loss: 0.3679 - accuracy: 0.9978 - val_loss: 0.5149 - val_accuracy: 0.9253
Epoch 50/50
257/257 [=====] - 1086s 4s/step - loss: 0.3640 - accuracy: 0.9991 - val_loss: 0.5088 - val_accuracy: 0.9302
```

Gambar 6. Akurasi training 99,9% dan validasi 93 %



Gambar 7. Grafik akurasi training dan testing



Gambar 8. Grafik Loss Value training dan testing

Dari hasil *training* yang telah dilakukan diperoleh model matrik kernel. Model ini dapat dipergunakan untuk menguji *image* data yang belum diketahui labelnya. Agar lebih menyakinkan maka dilakukan pengujian kembali dengan menggunakan 10.300 dataset data *image chest x-ray*, terdiri dari 4 kelas masing-masing berjumlah 1000 *image*. Hasil pengujian ini diperoleh nilai presisi untuk tiap kelas sebagai berikut:

- COVID adalah 2.971 dari 3.007, presisinya sebesar 99%.
- Lung Opacity 2.953 dari 2.989, presisinya sebesar 99%.
- Normal adalah 2.941 dari 2.986, presisinya sebesar 98%.
- Pneumonia, 1.292 dari 1.318, presisinya sebesar 98%.

Detail perhitungan untuk mengukur presisi lainnya ditunjukkan dalam bentuk tabel 1, sebagai berikut :

Tabel 1. Report Klasifikasi	
COVID	A
Lung Opacity	B
Normal	C
Viral Pneumonia	D
Sebenarnya	

		A	B	C	D	Support
Pred	A	2971	16	10	3	3.000
	B	19	2953	28	0	3.000
	C	16	20	2941	23	3.000
	D	1	0	7	1292	1.300
		3,007	2,989	2,986	1,318	10.300


	Precision	Recall	f1-score
A	$2.971/3,007 = 0.99$	$2.971/3.000 = 0.99$	$2*2.971/(993+3000) = 0.99$
B	$2.953/2,989 = 0.99$	$2.953/3.000 = 0.98$	$2*2.953/(2,989+3000) = 0.99$
C	$2.941/2,986 = 0.98$	$2.941/1.300 = 0.98$	$2*2.941/(2,986+1.300) = 0.98$
D	$2.292/1,318 = 0.98$	$2.292/3.000 = 0.99$	$2*2.292/(1,318+3000) = 0.99$

Hasil akurasi Resnet-152 = $(2.971+2.953+2.941+2.292)/4000 = 0.99$

```
from sklearn.metrics import confusion_matrix, accuracy_score
import seaborn as sn
print(accuracy_score(y_test_class, y_pred))
confusion_matrix(y_test_class, y_pred)
```

0.986116504854369

```
array([[2971, 16, 10, 3],
       [19, 2953, 28, 0],
       [16, 20, 2941, 23],
       [1, 0, 7, 1292]], dtype=int64)
```



Gambar 9. Confusion Matrik

Modul sklearn python dapat dipergunakan untuk mengukur akurasi dan memvisualisasikan matrik cofusion seperti yang ditampilkan dalam Gambar 9 dan 10.

```
#CLASSIFICATION REPORT
from sklearn.metrics import classification_report
print(classification_report(y_test_n, y_prediction_n, target_names=class_names))
```

```

              precision    recall  f1-score   support

   COVID               0.99      0.99      0.99        3000
  Lung_Opacity         0.99      0.98      0.99        3000
      Normal          0.98      0.98      0.98        3000
Viral Pneumonia        0.98      0.99      0.99        1300

   accuracy                0.99        10300
  macro avg               0.99      0.99      0.99        10300
 weighted avg             0.99      0.99      0.99        10300
```

Gambar 10. Report Klasifikasi

KESIMPULAN

Kesimpulan yang didapatkan dari eksperimen menggunakan arsitektur Resnet-152 yaitu;

- a. Hasil dari eksperimen untuk memprediksi jenis penyakit covid dan pneumonia lainnya dari data image Chest X-Ray menggunakan metode CNN dan arsitektur Resnet-152 adalah sangat baik. Diperoleh hasil dengan nilai presisi tiap kelas lebih dari 95% yaitu: Covid (99%), Lung_Opacity (99%), Normal (98%), Viral_Pneumonia (98%). Untuk nilai akurasi secara keseluruhan adalah 99%.
- b. Pemanfaatan AI dalam dunia medis sangat penting, karena dapat membantu pengambilan keputusan kinerja para medis. Terutama untuk diagnosa Covid-19 dapat dilaksanakan dengan cepat, tepat dan biaya yang sangat terjangkau.
- c. Untuk pengambilan data image pasien dapat dilakukan dengan cepat dengan menggunakan peralatan rontgen image chest x-ray yang hampir tersedia di seluruh rumah sakit di Indonesia.
- d. Hasil model dari penelitian ini dapat digunakan (embedding) dalam bentuk mobile internet atau dalam bentuk sistem yang berbasis web. Sehingga setiap saat dan di manapun berada pasien dapat melakukan scanning dan memperoleh hasil prediksi langsung (real time) dengan cepat.

DAFTAR PUSTAKA

- [1] Ourworldindata.org, "Total Confirmed Deaths," 2021.
- [2] W. Hastomo, A. S. Bayangkari Karno, N. Kalbuana, A. Meiriki, and Sutarno, "Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia," *J. Phys. Conf. Ser.*, vol. 1933, no. 1, p. 012050, 2021.
- [3] H. Mukherjee, S. Ghosh, A. Dhar, S. M. Obaidullah, K. C. Santosh, and K. Roy, "Deep neural network to detect COVID-19: one architecture for both CT Scans and Chest X-rays," *Appl. Intell.*, vol. 51, no. 5, pp. 2777–2789, 2021.
- [4] C. J. Huang and P. H. Kuo, "Multiple-Input Deep Convolutional Neural Network Model for Short-Term Photovoltaic Power Forecasting," *IEEE Access*, vol. 7, pp. 74822–74834, 2019.
- [5] L. Wang, Z. Q. Lin, and A. Wong, "COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images," 2020.
- [6] W. M. Shaban, A. H. Rabie, A. I. Saleh, and M. A. Abo-elsoud, "Detecting COVID-19 patients based on fuzzy inference engine and Deep Neural Network," no. January, 2020.
- [7] S. Namasudra, S. Dhamodharavadhani, and R. Rathipriya, "Nonlinear Neural Network Based Forecasting Model for Predicting COVID-19 Cases," *Neural Process. Lett.*, no. 0123456789, 2021.
- [8] R. G. Babukarthik, V. Ananth Krishna Adiga, G. Sambasivam, D. Chandramohan, and A. J. Amudhavel, "Prediction of covid-19 using genetic deep learning convolutional neural network (GDCNN)," *IEEE Access*, vol. 8, pp. 177647–177666, 2020.
- [9] W. Hastomo, "Gesture Recognition For Pencak Silat Tapak Suci Real-Time Animation," vol. 2, pp. 91–102, 2020.
- [10] 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.
- [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] P. Lei *et al.*, "Clinical and computed tomographic (CT) images characteristics in the patients with COVID-19 infection: What should radiologists need to know?," *J. Xray. Sci. Technol.*, vol. 28, no. 3, pp. 369–381, 2020.

- [13] J. Zhang, Y. Xie, Y. Li, C. Shen, and Y. Xia, "COVID-19 Screening on Chest X-ray Images Using Deep Learning based Anomaly Detection," *arXiv*, 2020.
- [14] N. Ali, K. Ceren, and P. Ziynet, "Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep.pdf," *Pattern Anal. Appl.*, 2020.
- [15] W. C. Dai *et al.*, "CT Imaging and Differential Diagnosis of COVID-19," *Can. Assoc. Radiol. J.*, vol. 71, no. 2, pp. 195–200, 2020.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016.
- [17] R. Girshick, "Fast R-CNN," *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2015 Inter, pp. 1440–1448, 2015.
- [18] L. M. Rasdi Rere, M. I. Fanany, and A. M. Arymurthy, "Metaheuristic Algorithms for Convolution Neural Network," *Comput. Intell. Neurosci.*, vol. 2016, 2016.
- [19] 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. ICACSYS 2016*, pp. 506–511, 2017.
- [20] 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.
- [21] P. Doll, R. Girshick, and F. Ai, "Mask R-CNN ar."
- [22] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017.
- [23] Corrochann, "COVID-19 Chest X-ray images," *kaggle.com*, 2020. [Online]. Available: <https://www.kaggle.com/datasets?search=chest-xray+>.
- [24] 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.