

## Deteksi Covid-19 pada Citra Sinar-X Dada Menggunakan *Pre-Training Deep Autoencoder*

### *Covid-19 Detection on X-Ray Images using Deep Autoencoder as Pre-Training*

FADHIL YUSUF RAHADIKA<sup>1\*</sup>, KARINA AMADEA<sup>1</sup>, ADHI SETIAWAN<sup>1</sup>, GRISELDA ANJELI SIRAIT<sup>1</sup>, NOVANTO YUDISTIRA<sup>1</sup>

#### Abstrak

Deteksi Covid-19 umumnya menggunakan tes laboratorium dengan metode RT-PCR untuk mendapatkan hasil yang akurat. Sayangnya, tes ini membutuhkan waktu yang cukup lama yaitu sekitar 24 jam untuk mendapatkan hasil. Selain menggunakan RT-PCR, beberapa penelitian menunjukkan bahwa deteksi menggunakan citra sinar-X menunjukkan hasil yang cukup akurat dengan waktu prediksi yang lebih cepat. Citra sinar-X yang didominasi warna dalam jangkauan *grayscale* dapat dikatakan memiliki karakteristik yang berbeda jika dibandingkan dengan citra secara umum, sehingga dalam penelitian ini eksperimen dilakukan terhadap pelatihan untuk kasus klasifikasi citra sinar-X dengan melatih model dari awal (*scratch*). Namun seringkali model yang dilatih tanpa adanya *pretraining* menyebabkan model tidak dapat mencapai performa yang cukup baik. Salah satu bentuk metode *pretraining* yang dapat digunakan adalah penggunaan *autoencoder* sebagai model untuk rekonstruksi citra. Dalam penelitian ini pelatihan menggunakan *pretraining autoencoder* menghasilkan akurasi terbaik sebesar 81.78% dengan tambahan metode *CutMix*, *color manipulation*, dan *rotation* sebagai augmentasi. Kami juga menunjukkan bahwa penambahan *pretraining autoencoder* secara konsisten dapat meningkatkan akurasi hingga 2.58% pada model yang dilatih dari awal (*scratch*).

Kata kunci: *autoencoder*, Covid-19, *pretraining*, sinar-X.

#### Abstract

*Covid-19 detection generally uses laboratory tests with the RT-PCR method to get accurate results. Unfortunately, this test takes a long time, which is around 24 hours to get the results. Apart from using the RT-PCR test, several studies have shown that detection using X-ray images performs fairly accurate results with a faster prediction time. X-ray images that are constructed by grayscale color have different characteristics compared to the image in common, thus experiments were carried out in this study focused on the training of the X-ray image classification model from scratch. But often a model that is trained without pretraining causes the model to not achieve good performance. One form of pretraining method that can be used is by incorporating an unsupervised autoencoder as a model for image reconstruction. In this study, training using pretraining autoencoder achieved the best accuracy of 81.78% with the addition of the CutMix method, color manipulation, and rotation as augmentation. We also showed that adding autoencoder pretraining can increase accuracy consistently by up to 2.58% in the model trained from scratch.*

Keywords: *autoencoder*, Covid-19, *pretraining*, X-ray.

## PENDAHULUAN

Pada akhir 2019, *coronavirus disease 2019* (Covid-19) menyebar luas di seluruh dunia sehingga Organisasi Kesehatan Dunia (WHO) menetapkan virus ini sebagai pandemi global

pada awal 2020 (Huang *et al.* 2020). Jumlah kasus Covid-19 menyebar cepat hingga ke beberapa negara di dunia. Terhitung hingga 3 Maret 2020, secara global dilaporkan 90 870 kasus konfirmasi di 72 negara dengan 3112 kematian (CFR 3.4%) (Kemenkes 2020). Covid-19 memiliki gejala umum antara lain demam (suhu tubuh di atas 38°C), batuk kering, dan sesak napas (WHO 2020). Pada kasus yang lebih parah infeksi Covid-19 bisa menyebabkan komplikasi seperti pneumonia, gagal ginjal, hingga kematian.

Deteksi dini Covid-19 menjadi semakin penting melihat cepatnya penyebaran virus ini dan tingkat berbahayanya. Metode diagnosis umum yang digunakan saat ini adalah RT-PCR yang setidaknya membutuhkan proses 24 jam dan tidak sepenuhnya akurat sehingga bisa memerlukan tes RT-PCR kedua untuk memastikan diagnosis (Islam *et al.* 2020). Cara lainnya yaitu dengan melakukan pemindaian gambar sinar-X dan *computed tomography* (CT) scan, kedua pemindaian gambar ini dapat membantu dalam menemukan diagnosis dini virus ini dengan lebih cepat dan akurat (Dansana *et al.* 2020). *CT scan* memiliki keunggulan lebih cepat dalam penghasil informasi namun biayanya yang mahal dan dapat meningkatkan risiko kanker dibandingkan dengan prosedur pencitraan sinar-X konvensional (foto rontgen) yang lebih umum. Di sisi lain, sinar-X memiliki keunggulan yaitu biaya yang lebih terjangkau dan banyak tersedia di fasilitas kesehatan pada umumnya (Dai *et al.* 2020).

Sebuah pemanfaatan sistem kecerdasan buatan akan membantu proses deteksi dini Covid-19 dengan mengklasifikasikan hasil gambar pemindaian sinar-X sehingga akan membantu petugas medis dalam mempercepat waktu diagnosis dan mendapatkan hasil yang akurat. Namun dengan keterbatasan data sinar-X Covid-19 yang sudah terlabeli saat ini membuat sistem kecerdasan buatan hanya bisa belajar dari data yang terbatas. Di sisi lain *autoencoder* dapat ditambahkan sebagai metode *pretraining* secara *unsupervised* untuk mengkalibrasi bobot awal jaringan syaraf tiruan (JST). *Autoencoder* merupakan salah satu jenis JST yang dapat digunakan untuk mengurangi dimensi fitur (*dimensionality reduction*) dan merekonstruksinya kembali menjadi bentuk awalnya. Keuntungan dari *unsupervised learning* di antaranya yaitu tidak membutuhkan pelabelan untuk melatih *layer* konvolusi, sedangkan data ke depannya akan semakin bertambah dan akan memakan usaha serta biaya yang tinggi untuk melabeli dan melatih *layer* konvolusi tersebut. Pada penelitian ini, dari hasil pelatihan *autoencoder* hanya digunakan pada bagian *encoder* saja yang akan di-*finetuning* untuk proses klasifikasi citra sinar-X untuk mendeteksi seseorang terserang Covid-19, pneumonia, atau sehat.

Ozturk *et al.* (2020) melakukan penelitian dan *dataset* yang sama menggunakan model DarkNet dengan menerapkan 17 *layer* konvolusi dan menggunakan filter yang berbeda pada setiap *layer* mendapatkan akurasi 87.02% untuk *multiclass classification* yaitu Covid-19, pneumonia, dan normal. Yudistira *et al.* (2020) juga melakukan penelitian serupa dengan membandingkan antara tiga model yaitu ShuffleNet, EfficientNet, dan ResNet50 dengan CNN FullConv dan mendapatkan akurasi sebesar 86.93% pada model ShuffleNet dengan jumlah parameter model yang lebih kecil 18.55 kali dari EfficientNet dan 22.36 kali lebih kecil dari ResNet50. Minaee *et al.* (2020) melakukan penelitian serupa menggunakan citra X-ray dada dan perbandingan terhadap beberapa arsitektur yang berbeda yaitu ResNet18, ResNet50, SqueezeNet, dan DenseNet-121. Hasil evaluasi terhadap beberapa model tersebut mendapatkan nilai *sensitivity rate* kurang lebih 98% dan *specificity rate* 90%.

Perbedaan yang ada pada penelitian sebelumnya dengan penelitian ini adalah penggunaan model atau arsitektur yang digunakan, selain itu pada penelitian terdahulu banyak yang sepenuhnya hanya menerapkan *supervised learning* (Abbas *et al.* 2021; Taresh *et al.* 2021; Turkoglu 2021). Penggunaan *unsupervised learning* pada penelitian ini akan memberikan keuntungan karena tidak membutuhkan pelabelan untuk melatih *layer* konvolusi. Namun demikian, jenis *unsupervised learning* lebih menantang karena seringkali menghasilkan akurasi yang lebih rendah daripada *supervised learning* karena tidak adanya supervisi. Penelitian sebelumnya tentang model *unsupervised learning* berbasis *stacked-autocencoder* untuk deteksi Covid-19 hanya dilatih pada set data citra CT dengan 2 kelas (Li *et al.* 2020). Sedangkan pada

penelitian ini, *autoencoder* dilatih pada citra X-ray dengan 3 kelas yaitu pneumonia, Covid-19, dan normal yang lebih menarik untuk dieksplorasi lebih lanjut.

## METODE

### *Dataset dan Preprocessing*

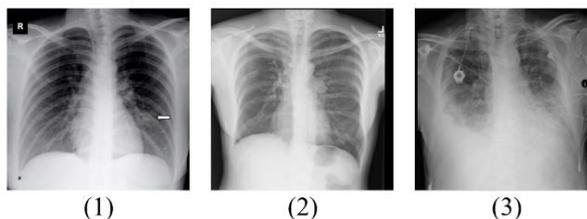
Pada penelitian ini, *dataset* yang digunakan adalah citra sinar-X Covid-19 sebanyak 1125 citra yang terbagi atas 3 kelas. Pada 1125 citra tersebut terdapat 125 citra pasien positif Covid-19, 500 citra normal, dan 500 citra pneumonia. *Dataset* tersebut dapat diunduh di alamat <https://github.com/muhammedtalo/covid-19> (Ozturk *et al.* 2020). Contoh dari *dataset* ini dapat dilihat pada Gambar 1 yang menunjukkan citra paru-paru terpapar Covid-19, normal, dan terpapar pneumonia.

Penelitian ini menggunakan dua tahap *preprocessing*, yaitu normalisasi dan augmentasi data. Normalisasi data digunakan untuk membuat nilai data berada dalam suatu rentang tertentu dengan tujuan membantu proses pelatihan menjadi jauh lebih cepat. Augmentasi data digunakan untuk meningkatkan variasi data tambahan yang dapat mengoptimalkan performa pelatihan dari model *deep learning* (Wang dan Perez 2017). Pada penelitian ini, normalisasi data menggunakan nilai rata-rata dan standar deviasi secara manual, sedangkan augmentasi data menggunakan metode transformasi data yaitu fungsi ColorJitter atau pengaturan warna HSV dan fungsi RandomHorizontalFlip atau rotasi.

### Model Arsitektur

*Convolutional neural network* (CNN) adalah salah satu metode klasifikasi dalam bidang *deep learning* yang memiliki operasi konvolusi untuk mengekstraksi fitur dari data *input*. CNN terbagi atas dua tahapan utama yaitu *feature learning* dan *classification*. Pada tahapan pertama terdiri atas *convolution layer*, ReLU (fungsi aktivasi), dan *pooling layer*. Sedangkan pada tahap kedua terdiri atas *flatten*, *fully-connected layer*, dan hasil prediksi. Pada setiap bagian tahapan terdapat dua proses utama, yaitu *feed-forward* dan *backpropagation* (O'Shea dan Nash 2015).

Ada 2 model arsitektur CNN yang digunakan dalam penelitian ini yang bertujuan untuk merekonstruksi citra sinar-X Covid-19, yaitu model AlbuNet dan *residual neural network* (ResNet). Model AlbuNet merupakan modifikasi dari model LinkedNet dengan model ResNet sebagai versi dari proses *autoencoder* (Shvets *et al.* 2018). ResNet merupakan salah satu arsitektur yang cukup populer dan memiliki berbagai macam jenis arsitektur, mulai dari 18, 34, 50, 101, sampai 152 *layer* (He 2016). Berdasarkan jenis arsitektur tersebut, ResNet-18 yang hanya memiliki 18 *layer* dipilih sebagai model untuk melakukan proses *autoencoder* karena keterbatasan *hardware* dan waktu pengerjaan.



Gambar 1 Citra paru-paru yang (1) terpapar Covid-19, (2) normal, (3) terpapar pneumonia (Yudistira *et al.* 2020)

### *Mixed Sample Data Augmentation*

Pada pelatihan model JST sering kali ditemukan fenomena *overfitting*, yaitu model terlalu fokus belajar pada data latih yang minim variasi polanya sehingga ketika dilakukan pengujian pada data uji akan banyak terdapat kesalahan jika terdapat data dengan pola di luar variasi data latih. Masalah *overfitting* ini salah satunya dapat ditangani dengan cara menambah metode

augmentasi terhadap data salah satunya dengan *mixed sample data augmentation* (MSDA) yang menggabungkan fitur-fitur yang dimiliki beberapa data menjadi satu.

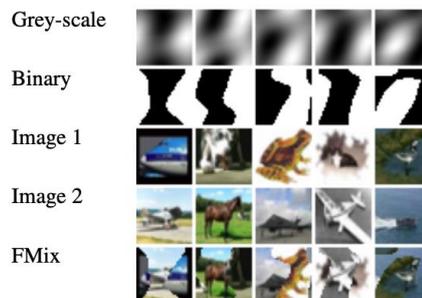
- a. *Mixup*. Mixup bekerja dengan mengombinasikan warna dari dua citra dan labelnya. Pada beberapa eksperimen yang telah diterapkan pada kumpulan data ImageNet-2012, CIFAR-10, CIFAR-100, Google, dan UCI menunjukkan bahwa Mixup dapat meningkatkan kemampuan generalisasi arsitektur JST yang canggih. Penelitian tersebut juga menemukan bahwa *mixup* dapat mengurangi pengenalan label yang tidak lengkap dan menstabilkan pelatihan *adversarial generative networks* (Zhang *et al.* 2018). Ilustrasi hasil augmentasi mixup dapat dilihat pada Gambar 2.
- b. *CutMix*. CutMix merupakan salah satu jenis augmentasi data citra yang pada prosesnya melakukan *cut* dan *paste* pada bagian acak piksel pada sebuah data latih citra. CutMix diusulkan untuk menggantikan salah satu metode *regional dropout* yang mengganti suatu bagian dari citra dengan piksel hitam. Hal ini bisa menghilangkan informasi penting yang terdapat dalam citra tersebut. Oleh karena itu daripada menghilangkan salah satu bagian dari citra lebih baik mengganti bagian yang dihilangkan tersebut dengan citra yang lain secara proporsional agar suatu model bisa lebih fokus pada bagian yang tidak terlalu diskriminatif pada objek (Yun *et al.* 2019). Ilustrasi hasil augmentasi CutMix dapat dilihat pada Gambar 3.
- c. *FMix*. FMix adalah salah satu bentuk metode augmentasi dengan teknik *masking* yang dihasilkan dari *Fourier space* secara acak yang berbentuk tidak teratur namun nilainya berkelanjutan sehingga fitur tersebut tetap terjaga korelasinya dengan fitur di sekitarnya, khususnya untuk data yang berjenis citra yang tiap piksel dapat berkorelasi kuat dengan piksel di sekitarnya. Pada penelitian yang sudah dilakukan sebelumnya, secara umum FMix dapat menghasilkan model dengan performa yang lebih baik dibanding metode MSDA yang sudah ada sebelumnya, seperti Mixup dan CutMix (Harris *et al.* 2020). Ilustrasi hasil augmentasi FMix dapat dilihat pada Gambar 4.



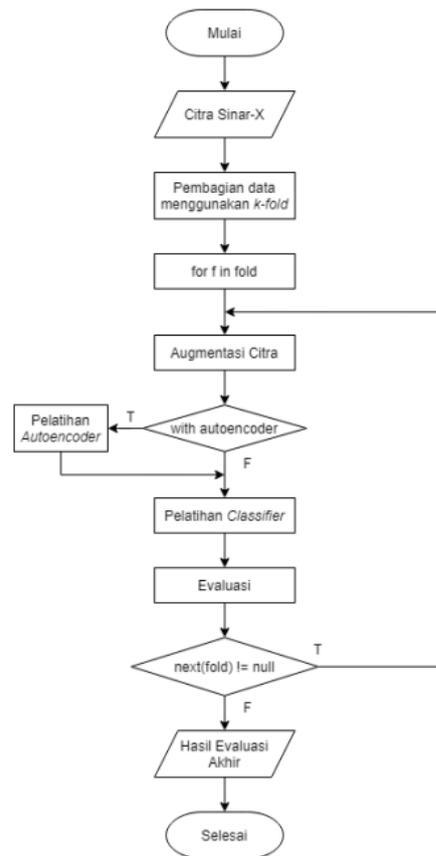
Gambar 2 Ilustrasi Mixup (Rugery 2020)



Gambar 3 Ilustrasi perbedaan hasil augmentasi Mixup, Cutout, dan CutMix (Yun *et al.* 2019)



Gambar 4 Ilustrasi FMix (Harris *et al.* 2020)



Gambar 5 Flowchart tahap pelatihan

### Tahap Pelatihan

Pada penelitian ini, pelatihan model dilakukan dengan dan tanpa arsitektur *autoencoder* dengan pembagian dataset menggunakan metode *k-fold cross validation* sebelum dilakukannya pemrosesan untuk augmentasi, pelatihan, dan *classifier*. Ilustrasi tahapan pelatihan dapat dilihat pada Gambar 5.

Pelatihan model dilakukan menggunakan platform Google Colab dengan akselerasi *graphical processing unit* (GPU) untuk mempercepat proses komputasi. Proses pelatihan model *autoencoder* sebagai *pretraining* memakan waktu sekitar 8 menit, sedangkan proses pelatihan model klasifikasi untuk *1-fold* memakan waktu sekitar 30 menit dengan jumlah 100 *epoch*. Platform ini menyediakan perangkat keras dengan spesifikasi 2 vCPU @ 2.2Ghz, 13 GB RAM, dan GPU Nvidia K80/T4/P4/P100. Tahap pelatihan model menggunakan platform Google Colab juga bertujuan untuk mensimulasikan proses inferensi untuk deteksi dini menggunakan platform yang mudah dijangkau. Perangkat lunak yang digunakan pada penelitian ini yaitu Python 3.6 dan Pytorch 1.8.

#### a. Tahap Pelatihan *Autoencoder*

*Autoencoder* adalah jenis arsitektur JST yang terdiri atas bagian *encoder* untuk ekstraksi fitur ke dimensi yang lebih kecil dan *decoder* untuk merekonstruksi ke ukuran aslinya. Kami menggunakan jenis *task* rekonstruksi citra untuk tahap pelatihan *autoencoder* dalam penelitian ini. Pembelajaran rekonstruksi citra adalah pelatihan yang bertujuan untuk mempelajari data masukan dan merekonstruksi terhadap data masukan tersebut sebagai pengurangan dimensi fitur.

Pada penelitian ini, digunakan arsitektur AlbuNet sebagai *autoencoder* yang terdiri dari lapisan sebagai berikut. Lapisan *input*: lapisan data citra dengan parameter ditentukan oleh ukuran data masukan citra. Kombinasi lapisan konvolusi dan *pooling*: lapisan konvolusi menghasilkan *feature map* dari data *input*, sedangkan lapisan *pooling* membantu dalam mengurangi *overfit*. Parameter lapisan ini dapat dilihat pada Tabel . Ilustrasi secara

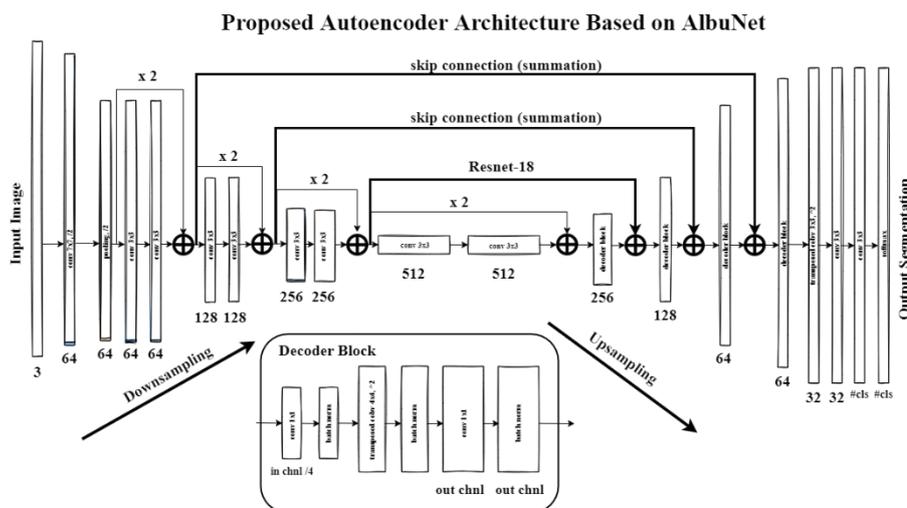
keseluruhan dari arsitektur autoencoder yang kami gunakan pada penelitian ini dapat dilihat pada Gambar 6.

b. Tahap Pelatihan *Classifier*

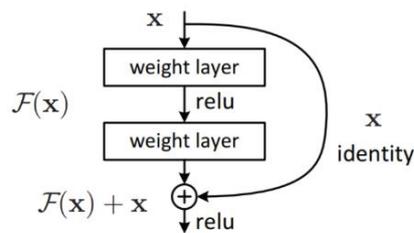
Pelatihan pada tahap ini adalah pelatihan akhir secara *supervised* setelah pelatihan *autoencoder*. Pada pelatihan ini, hanya menggunakan bagian *encoder* saja dari *autoencoder* untuk mengklasifikasikan data. Tahap setelah diambil *encoder*-nya saja, jaringan kembali ke bentuk awalnya yaitu ResNet-18. ResNet adalah arsitektur berbasis CNN dengan penambahan adanya jalur *shortcut* yang dinamakan *residual connection* di antara blok CNN untuk mengatasi masalah *vanishing gradient* (He *et al.* 2016). Ilustrasi dari *residual connection* pada arsitektur ResNet-18 dapat dilihat pada Gambar 7.

Tabel 1 Arsitektur *autoencoder*

Nama layer	Ukuran output	18-layer
conv1	112x112	7 x 7, 64 filter, stride 2, padding 3
conv2	56x56	3 x 3 max pooling, stride 2, padding 1
conv3	28x28	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$
conv4	14x14	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$
conv5	7x7	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$
decoder1	14x14	$\begin{bmatrix} conv\ 1 \times 1, 256 \\ trans\ 4 \times 4, stride\ 2 \\ conv\ 1 \times 1, 256 \\ conv\ 1 \times 1, 128 \end{bmatrix}$
decoder2	28x28	$\begin{bmatrix} trans\ 4 \times 4, stride\ 2 \\ conv\ 1 \times 1, 128 \\ conv\ 1 \times 1, 64 \end{bmatrix}$
decoder3	56x56	$\begin{bmatrix} trans\ 4 \times 4, stride\ 2 \\ conv\ 1 \times 1, 64 \\ conv\ 1 \times 1, 64 \end{bmatrix}$
decoder4	112x112	$\begin{bmatrix} trans\ 4 \times 4, stride\ 2 \\ conv\ 1 \times 1, 64 \end{bmatrix}$
decoder5	224x224	trans 3 x 3, stride 2
decoder6	224x224	conv 3 x 3, 32
decoder7	224x224	conv 2 x 2, 3



Gambar 6 Ilustrasi arsitektur *autoencoder* penelitian ini yang berdasar dari arsitektur AlbuNet (Shvets *et al.* 2018)

Gambar 7 Ilustrasi arsitektur ResNet (He *et al.* 2015)

Tabel 2 Hasil eksplorasi augmentasi

HFlip	Bright 0.25	Saturation 0.25	Hue 0.1	Rotate 15°	Akurasi
					0.7973
				✓	0.8124
			✓		0.7902
		✓			0.8036
	✓				0.7724
✓					0.7876
		✓		✓	0.8178*

Tabel 3 Hasil eksplorasi *mixed sample data augmentation* (MSDA)

Metode	Non-MSDA	Mixup	CutMix	FMix	Akurasi	Stdev
	✓				0.8116	0.0196
Bobot awal <i>random</i>		✓			0.7369	0.0247
			✓		0.8027	0.0134
				✓	0.8089	0.0250
Bobot awal hasil <i>autoencoder</i>	✓				0.8133	0.0161
		✓			0.7627	0.0462
			✓		0.8178	0.0388
				✓	0.8133	0.0375

## HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan percobaan untuk menerapkan *autoencoder* sebagai *pre-training* dalam kasus klasifikasi citra sinar-X dada yang mempunyai 3 kategori, yaitu normal, pneumonia, dan Covid-19. Pada tahap sebelumnya telah dilakukan pelatihan terhadap model AlbuNet yang menggunakan Resnet-18 sebagai *encoder*-nya dengan *batch size* sebesar 256, *learning rate* sebesar  $1 \times 10^{-4}$ , dan Adam sebagai *optimizer*.

Pengujian model tersebut dilakukan percobaan menggunakan validasi silang 5. Pada setiap percobaan tersebut menggunakan perbandingan data latih dan data uji dalam setiap percobaan adalah sebesar 80:20. Pada penelitian ini juga diterapkan augmentasi tipe putar (*rotate*), balik (*horizontal flip*), dan pengaturan warna (*saturation, brightness, hue*) untuk meningkatkan variasi pola citra. Dalam penerapannya, didapatkan hasil bahwa akurasi model akan mengalami kenaikan terbesar jika menerapkan gabungan dari tipe augmentasi *rotate* dan *saturation* seperti yang terlihat pada Tabel .

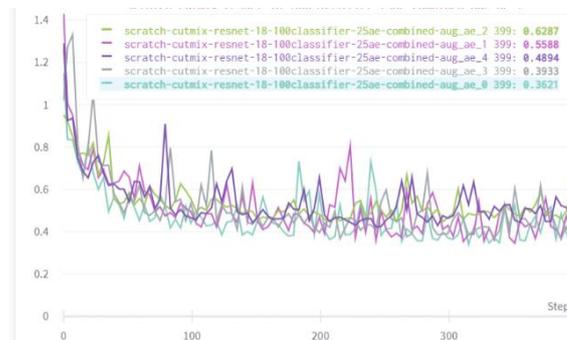
Pada saat dilakukan percobaan, metode augmentasi yang digunakan pada percobaan terakhir bertambah kompleks, sehingga khusus pada percobaan tersebut kami menaikkan *epoch*-nya dari 25 menjadi 50. Tidak hanya augmentasi, kami juga melakukan normalisasi pada data menggunakan rataan dan standar deviasi dari data latih tiap *fold cross validation*.

Eksplorasi juga dilakukan pada data dengan menerapkan metode MSDA untuk melokalisir fitur-fitur yang terdapat pada data dengan menggunakan 100 *epoch*. Pada eksplorasi ini didapatkan akurasi terbesar dengan menggunakan MSDA jenis CutMix seperti yang terlihat pada Tabel . Pada hasil tersebut juga dapat membuktikan bahwa metode *pre-training* dengan *autoencoder* menunjukkan peningkatan performa pada *dataset* citra sinar-X dibandingkan menggunakan bobot awal secara acak. Rata-rata nilai *loss* yang dihasilkan dari eksplorasi

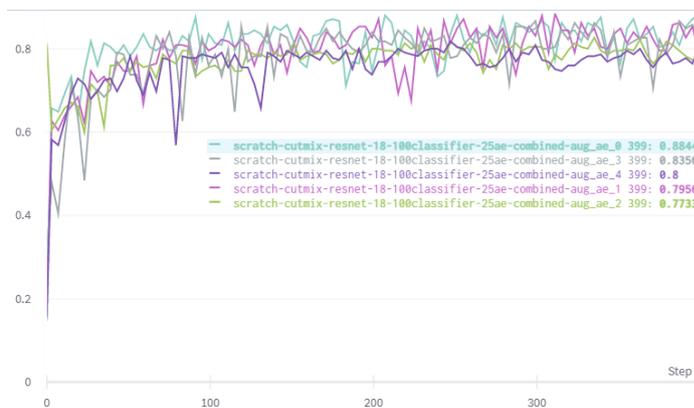
*autoencoder* dari tiap *fold* dengan Cutmix yaitu sebesar 0.486. Grafik nilai *loss* dan akurasi pada tiap *fold* selama pelatihan secara berturut-turut dapat dilihat Gambar 8 dan Gambar 9.

Pada Tabel 4 dapat dilihat bahwa hasil prediksi Covid-19 dan menghasilkan prediksi yang benar ada 104 data dari 125 data. Lima data terprediksi sebagai normal, dan 16 data terprediksi pneumonia. Kemudian pada bagian hasil prediksi normal, ada 428 data yang terprediksi secara benar dan 72 data salah prediksi sebagai pneumonia. Selanjutnya pada bagian pneumonia ada 390 data yang terprediksi secara benar, 104 data salah prediksi sebagai normal, dan enam data terprediksi salah sebagai Covid-19.

Hasil pengujian model *autoencoder* dengan akurasi terbaik pada kasus klasifikasi dirangkum dalam *confusion matrix* agar selanjutnya dapat diolah menjadi metrik yang lebih spesifik seperti *precision*, *recall*, dan *f1-score*. *Confusion matrix* pada Tabel juga dapat menunjukkan bahwa model tidak dapat memisahkan kelas citra sinar-X dada kategori normal dan pneumonia dengan baik. Hal ini dapat dilihat dari *false positive* yang cukup besar di antara dua kelas ini yang bisa disebabkan karena kemiripan fitur di antara dua kelas tersebut dan model yang sudah kami latih tidak dapat membedakannya berdasarkan fitur yang telah diekstraksi. Berdasarkan Tabel juga, dapat dilihat bahwa model sudah cukup baik mengklasifikasikan data dengan label Covid-19 dengan *false negative* yang lebih kecil terhadap dua kelas lainnya.



Gambar 8 Loss terhadap data validasi selama pelatihan dengan *autoencoder* dan Cutmix



Gambar 9 Akurasi terhadap data validasi selama pelatihan dengan *autoencoder* dan Cutmix

Tabel 4 *Confusion Matrix* AlbuNet-18 + *autoencoder* + Cutmix dengan 5-fold cross validation

	Covid-19	normal	pneumonia
Covid-19	104	5	16
normal	0	428	72
pnumonia	6	104	390

Tabel 5 Perhitungan metrik hasil pengujian

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Covid-19	94.55%	83.20%	88.51%
normal	79.70%	85.60%	82.54%
pneumonia	81.59%	78.00%	79.75%

Hasil pengolahan *confusion matrix* menjadi metrik yang spesifik disajikan pada Tabel . Dari tabel tersebut dapat dihitung juga *macro-precision* sebesar 85.28%, *macro-recall* sebesar 82.27%, dan *macro-F1* sebesar 83.6% yang dihitung dari rata-rata metrik di tiap kelas.

## SIMPULAN

Hasil eksperimen yang telah dilakukan terhadap metode augmentasi gabungan antara manipulasi warna pada *channel saturation* dan pemutaran citra menunjukkan peningkatan akurasi mencapai 2.05% terhadap *baseline* yang dilatih tanpa menggunakan metode augmentasi. Selain itu, dalam eksperimen penggunaan MSDA pada citra sinar-X didapatkan hasil bahwa pengaplikasian Mixup selalu menunjukkan penurunan performa baik menggunakan *autoencoder* ataupun tanpa menggunakan *autoencoder*, sedangkan CutMix dan FMix juga menunjukkan penurunan performa namun hanya pada pelatihan model tanpa menggunakan *autoencoder* sebagai *pretraining*. Secara umum, pelatihan menggunakan *autoencoder* sebagai *pretraining* pada kasus klasifikasi citra sinar-X untuk deteksi Covid-19 dan pneumonia menunjukkan peningkatan akurasi secara konsisten terhadap seluruh konfigurasi pengujian tanpa *autoencoder*. Peningkatan performa penggunaan *autoencoder* sebagai *pretraining* mulai dari 0.17% pada hasil pelatihan tanpa MSDA yang naik dari 81.16% pada pelatihan tanpa *autoencoder* ke 81.33% pada pelatihan dengan *autoencoder*. Puncaknya dapat dilihat pada pelatihan dengan MSDA Mixup yang naik dari 73.69% pada pelatihan tanpa *autoencoder* ke 76.27% pada pelatihan dengan *autoencoder*.

## DAFTAR PUSTAKA

- Abbas A, Abdelsamea MM, Gaber MM. 2021. Classification of Covid-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*. 51(2): 854–864. doi: 10.1007/s10489-020-01829-7.
- Dai WC, Zhang HW, Yu J, Xu HJ, Chen H, Luo SP, Zhang H, Liang LH, Wu XL, Lei Y, *et al.* 2020. CT imaging and differential diagnosis of Covid-19. *Canadian Association of Radiologists Journal*. 71(2): 195–200. doi: 10.1177/0846537120913033.
- Dansana D, Kumar R, Bhattacharjee A, Hemanth DJ, Gupta D, Khanna A, Castillo O. 2020. Early diagnosis of Covid-19-affected patients based on X-ray and computed tomography images using deep learning algorithm. *Soft Comput*. doi: 10.1007/s00500-020-05275-y.
- Harris E, Marcu A, Painter M, Niranjan M, Prugel-Bennet A, Hare J. 2020. FMix: enhancing mixed sample data augmentation. *ArXiv Preprint*. <https://arxiv.org/abs/2002.12047>.
- He K, Zhang X, Ren S, Sun J. 2016. Deep residual learning for image recognition. Di dalam: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. hlm 770–778.
- Huang C, Wang Y, Li X, Ren L, Zhao J, Hu Y, Zhang L, Fan G, Xu J, Gu X, *et al.* 2020. Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *The Lancet*. 395(10223): 497–506. doi: 10.1016/S0140-6736(20)30183-5.
- Islam N, Ebrahimzadeh S, Salameh J-P, Kazi S, Fabiano N, Treanor L, Absi M, Hallgrimson Z, Leeflang MMG, Hooft L, *et al.* 2020. Thoracic imaging tests for the diagnosis of Covid-19. *Cochrane Database of Systematic Reviews*. (3): CD013639. doi: 10.1002/14651858.CD013639.pub4.
- [Kemenkes] Kementerian Kesehatan RI. 2020. *Pedoman Pencegahan dan Pengendalian Covid-19*. Ed ke-3. Jakarta: Kementerian Kesehatan RI.
- Li D, Fu Z, Xu J. 2020. Stacked-autoencoder-based model for Covid-19 diagnosis on CT images. *Applied Intelligence*. 51(5): 2805–2817. doi: 10.1007/s10489-020-02002-w

- Minaee S, Kafieh R, Sonka M, Yazdani S, Soufi GJ. 2020. Deep-Covid: predicting Covid-19 from chest X-ray images using deep transfer learning. *Medical Image Analysis*. 65: 101794. doi: 10.1016/j.media.2020.101794.
- O'Shea K, Nash R. 2015. An introduction to convolutional neural networks. *arXiv Preprint*. <https://arxiv.org/abs/1511.08458>.
- Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Acharya UR. 2020. Automated detection of Covid-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*. (121): 103792. doi: 10.1016/j.combiomed.2020.103792.
- Perez L, Wang J. 2017. The effectiveness of data augmentation in image classification using deep learning. *ArXiv Preprint*. <https://arxiv.org/abs/1712.04621>.
- Rugery P. 2020. Explanation of YOLO V4 a one stage detector. <https://becominghuman.ai/explaining-yolov4-a-one-stage-detector-cdac0826cbd7>
- Shvets AA, Iglovikov VI, Rakhlin A, Kalinin AA. 2018. Angiodysplasia detection and localization using deep convolutional neural networks. Di dalam: *IEEE International Conference on Machine Learning and Applications (ICMLA)*. hlm 612–617. doi: 10.1109/ICMLA.2018.00098.
- Taresh MM, Zhu N, Ali TAA, Hameed AS, Mutar ML. 2021. Transfer learning to detect Covid-19 automatically from X-ray images using convolutional neural networks. *International Journal of Biomedical Imaging*. doi: 10.1155/2021/8828404.
- Turkoglu M. 2021. CoviDetectionNet: Covid-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*. 51(3): 1213–1226. doi: 10.1007/s10489-020-01888-w.
- [WHO] World Health Organization. 2020. Coronavirus disease (Covid-19). [diakses 2020 Des 6]. <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/question-and-answers-hub/q-a-detail/coronavirus-disease-covid-19>.
- Yudistira N, Widodo AW, Rahayudi B. 2020. Deteksi Covid-19 pada citra sinar-x dada menggunakan deep learning yang efisien. *Jurnal Teknologi Informasi dan Ilmu Komputer*. 7(6): 1289–1296. doi: 10.25126/jtiik.202073651.
- Yun S, Han D, Oh SJ, Chun S, Choe J, Yoo Y. 2019. CutMix: regularization strategy to train strong classifiers with localizable features. Di dalam: *IEEE/CVF International Conference on Computer Vision (ICCV)*. hlm 6023–6032.
- Zhang H, Cisse M, Dauphin YN, Lopez-Paz D. 2018. Mixup: beyond empirical risk minimization. *Arxiv Preprint*. <https://arxiv.org/abs/1710.09412>.