

DETEKSI COVID-19 PADA CITRA SINAR-X DADA MENGGUNAKAN *PRE-TRAINING DEEP AUTOENCODER*

Fadhil Yusuf Rahadika¹, Karina Amadea², Adhi Setiawan³, Griselda Anjeli Sirait⁴, Novanto Yudistira⁵

^{1,2,3,4,5}Universitas Brawijaya

Email: ¹fadhilyusuf27@gmail.com, ²kaamadea@gmail.com, ³adhisetiawan518@gmail.com,
⁴griseldasirait@gmail.com, ⁵yudistira@ub.ac.id

Abstrak

Pada awal tahun 2020, virus baru bernama COVID-19 diidentifikasi di kota Wuhan, China. Virus ini menyebar ke banyak negara dengan sangat cepat hingga pada waktu yang berdekatan WHO menetapkan virus tersebut sebagai pandemi. Virus ini menyerang sistem pernafasan dan dapat menyebabkan komplikasi terhadap penyakit lainnya seperti pneumonia, gagal ginjal, hingga dapat menyebabkan pengidap meninggal dunia. Deteksi virus COVID-19 ini 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 tes 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 mulai 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 membuktikan bahwa penambahan *pretraining autoencoder* secara konsisten dapat meningkatkan akurasi hingga 2,58% pada model yang dilatih dari awal (*scratch*).

Kata kunci: COVID-19, sinar-X, *pretraining*, *autoencoder*

COVID-19 DETECTION ON X-RAY IMAGES USING DEEP AUTOENCODER AS PRE-TRAINING

Abstract

In early 2020, a new virus named COVID-19 was identified in Wuhan, China. This virus spreads to other countries rapidly that in a short time WHO declared the virus as a pandemic. This virus attacks the respiratory system and can cause complications for other diseases such as pneumonia, kidney failure, and death. COVID-19 virus 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 training 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 proved that adding autoencoder pretraining can increase accuracy consistently by up to 2.58% in the model trained from scratch.

Keywords: COVID-19, X-ray, *pretraining*, *autoencoder*

1 PENDAHULUAN

Pada 31 Desember 2019, sebuah kasus pneumonia yang tidak diketahui asalnya menyerang beberapa orang di kota Wuhan, China. Jenis pneumonia ini semakin banyak menyerang warga seiring berjalannya waktu, sehingga pada tanggal 7 Januari 2020 China mengidentifikasi pneumonia yang tidak diketahui asalnya ini sebagai jenis baru dari *coronavirus* dan disebut COVID-19 (*Coronavirus Disease 19*) (HUANG, et al., 2020). Setiap harinya semakin banyak manusia yang terinfeksi oleh COVID-19, sampai akhirnya pada tanggal 30 Januari 2020 organisasi kesehatan dunia (WHO) menetapkan virus ini sebagai "Situasi Darurat Global" atau *Public Health Emergency of International Concern* (PHEIC). Jumlah kasus COVID-19 menyebar cepat hingga ke beberapa negara di dunia. Sampai dengan 3 Maret 2020, secara global dilaporkan 90.870 kasus konfirmasi di 72 negara dengan 3.112 kematian (CFR 3,4%) (KEMENTERIAN KESEHATAN REPUBLIK INDONESIA, 2020). Semakin banyaknya kasus COVID-19 di beberapa negara, akhirnya pada tanggal 11 Maret 2020, WHO menetapkan virus ini sebagai pandemi yang sangat berbahaya bagi kesehatan warga dunia. Virus ini menyebar dengan sangat cepat antar manusia dan bisa menginfeksi manusia lainnya yang memiliki kontak erat dengan yang terinfeksi. COVID-19 memiliki gejala umum yang menandakan seseorang sedang terserang virus ini atau tidak, gejala umum tersebut antara lain demam (suhu tubuh di atas 38 derajat), batuk kering, dan sesak napas (WORLD HEALTH ORGANIZATION, 2020). Pada kasus yang lebih parah infeksi COVID-19 bisa menyebabkan komplikasi seperti pneumonia, gagal ginjal, hingga kematian.

Tingkat berbahaya akibat dari COVID-19 inilah yang membuat para peneliti di dunia untuk melakukan deteksi dini seseorang terserang COVID-19 atau tidak. Hal ini bertujuan agar para pasien penderita COVID-19 bisa ditangani dengan cepat sebelum virus ini menyerang pasien dengan lebih kuat dan menyebar ke orang lain. Metode diagnosis umum yang digunakan untuk deteksi COVID-19 pada saat ini adalah dengan menggunakan RT-PCR, namun RT-PCR ini membutuhkan setidaknya 24 jam untuk memberikan hasilnya dan ini tidak sepenuhnya akurat bahkan bisa memerlukan tes RT-PCR kedua untuk memastikan diagnosis (SALAMEH, LEEFLANG, HOOFT, & ISLAM, 2020). Cara lain yang bisa dilakukan adalah dengan melakukan pemindaian gambar Sinar-X dan *Computed Tomography* (CT),

kedua pemindaian gambar ini dapat membantu dalam menemukan diagnosis dini untuk virus ini dengan lebih cepat dan akurat (DEBRABATA, et al., 2020). Meskipun dalam penghasilannya informasi lebih cepat, namun untuk melakukan CT Scan dibutuhkan biaya yang mahal. Risiko terjadinya kanker pada pasien yang menggunakan CT juga meningkat dikarenakan melibatkan lebih besar dosis penggunaan radiasi pengion dari prosedur pencitraan sinar-X konvensional (foto *Röntgen*) yang lebih umum. Berbeda dengan sinar-X yang biayanya lebih terjangkau. Radiografi Sinar-X juga telah dipasang di banyak daerah dari perkotaan hingga pedesaan dan di beberapa fasilitas kesehatan swasta yang menjadikannya salah satu alternatif pencitraan pertama yang dapat digunakan dalam pandemi COVID-19 (DAI, et al., 2020).

Sebuah pemanfaatan sistem kecerdasan buatan akan membantu proses deteksi dini COVID-19 dengan menggunakan hasil gambar pemindaian menggunakan sinar-X sehingga akan membantu petugas medis dalam mempercepat waktu diagnosis dan mendapatkan hasil yang akurat. Gambar hasil pemindaian sinar-X tersebut akan dideteksi seseorang terserang COVID-19, pneumonia, atau sehat dengan menggunakan klasifikasi citra. Dengan adanya solusi pendeteksi penggunaan masker tersebut maka bisa dibuat sebuah sistem kecerdasan buatan menggunakan arsitektur *deep learning* untuk melakukan klasifikasi citra yaitu *Autoencoder*.

Autoencoder merupakan salah satu jenis dari jaringan syaraf tiruan yang digunakan untuk mengurangi dimensi dari fitur (*Dimensionality Reduction*). *Autoencoder* sering digunakan pada kasus *unsupervised learning*, ketika sebuah citra dimasukkan maka *autoencoder* akan merekonstruksi citra tersebut untuk menghasilkan citra yang sama pada *output*. Keuntungan dari *unsupervised learning* diantaranya yaitu tidak membutuhkan pelabelan untuk melatih layer konvolusi, sedangkan data kedepannya akan semakin bertambah dan akan memakan usaha serta biaya yang tinggi untuk melabeli dan melatih layer konvolusi tersebut. *Autoencoder* digunakan pada penelitian ini karena ketika melakukan pelatihan dari awal (*scratch*), sulit menemukan akurasi yang bagus, oleh karena itu perlu pelatihan tambahan, salah satunya menggunakan *pretraining* dengan *autoencoder* untuk melakukan peningkatan data pada bagian *encoder*. Pada penelitian ini *autoencoder* hanya digunakan pada proses *encoder* saja, hasil dari *encoder* yang berupa latent akan dimasukkan pada *Fully Connected Layer* yang selanjutnya akan dilakukan *finetuning* klasifikasi pada proses tersebut. Hasil dari keluaran

(*output*) *fully connected layer* inilah yang nanti bisa menghasilkan klasifikasi citra sinar-X antara seseorang terinfeksi COVID-19, pneumonia, atau sehat.

Tulin Ozturk dan Muhammed Talo (2020) melakukan penelitian dan *dataset* yang sama menggunakan model Darknet dan mendapatkan hasil akurasi 98.08% pada *binary classification* yaitu COVID-19 dan Normal. Serta mendapatkan akurasi 87.02% untuk *multiclass classification* yaitu COVID-19, Pneumonia, dan Normal. Hasil tersebut didapatkan dengan menerapkan 17 layer konvolusi dan menggunakan filter yang berbeda pada setiap layer (OZTURK, et al., 2020). Novanto Yudistira, Agus Wahyu, dan Bayu Rahayudi (2020) juga melakukan penelitian serupa, pada penelitian tersebut melakukan pengujian dan membandingkan antara 3 model yaitu ShuffleNet, EfficientNet, dan ResNet50 dengan CNN FullConv. Dan didapatkan akurasi sebesar 86.93% pada model CNN FullConv dengan jumlah parameter model yang lebih kecil 18.55 kali dari EfficientNet, 22.36 kali lebih kecil dari ResNet50 untuk mendeteksi 3 kelas yaitu COVID-19, Pneumonia, dan Normal (YUDISTIRA, WIDODO, & RAHAYUDI, 2020). Shervin Minaee (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% (MINAEE, KAFIEH, SONKA, YAZDANI, & JAMALIPOUR, 2020). Iqbal Khan (2020) mengusulkan sebuah model baru yang diberi nama CoroNet, model ini berbasis pada arsitektur Xception yang telah dilakukan *pre-trained* pada *dataset* ImageNet. Pada penelitian tersebut menghasilkan nilai akurasi 89.6% untuk 4 label yaitu (COVID-19, pneumonia *bacterial*, pneumonia *viral*, dan normal) serta mendapatkan nilai akurasi 95% untuk 3 label yaitu (COVID-19, pneumonia, dan normal) (KHAN, SHAH, & BHAT, 2020). Harsh Panwar (2020) juga melakukan penelitian yang sama, pada penelitian tersebut mengusulkan sebuah arsitektur baru yang diberi nama nCOVnet. Pada hasil akhir mendapatkan akurasi sebesar 93% dan ketika dilakukan pengujian mendapatkan hasil prediksi sekitar 97% kebenaran untuk COVID-19 dan 98.67% untuk normal (PANWAR, GUPTA, SIDDIQUI, MENENDEZ, & SINGH, 2020).

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* (TURKOGLU, 2021) (ABBAS, ABDELSAMEA, & GABER, 2021) (TARESH,

ZHU, & ALI, 2020). Penggunaan *supervised learning* akan menyulitkan karena dimasa yang akan datang, data akan semakin bertambah banyak dan itu akan memerlukan waktu dan usaha yang cukup besar untuk melakukan pemberian label pada data dan melakukan pelatihan untuk keseluruhan arsitekturnya. Penggunaan *unsupervised learning* pada penelitian ini akan memberikan keuntungan karena tidak membutuhkan pelabelan untuk melatih layer konvolusi. Namundemikian, jenis *unsupervised learning*

lebih menantang dikarenakan sering kali menghasilkan akurasi yang lebih rendah daripada *supervised learning* dikarenakan 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, FU, & XU, 2020). Sedangkan pada penelitian yang kami lakukan, Autoencoder dilatih pada citra X-ray dengan 3 kelas yaitu Pneumonia, COVID-19, dan normal yang tentunya lebih menantang untuk dieksplorasi lebih lanjut.

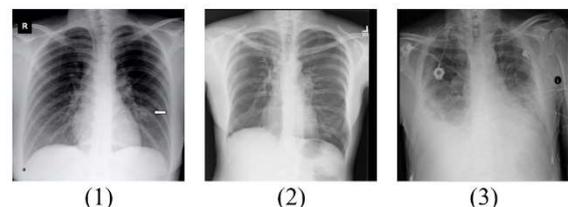
2 METODE PENELITIAN

2.1 Dataset dan Preprocessing

Pada penelitian ini, *dataset* yang digunakan adalah *dataset* citra sinar-X COVID-19 sebanyak 1125 citra yang terbagi atas 3 kelas. Dari 1125 citra terdapat 125 citra pasien positif COVID-19, 500 citra *No findings* (Normal), dan 500 citra Pneumonia. *Dataset* tersebut dapat diunduh di alamat

<https://github.com/muhammedtalo/COVID-19>.

Contoh dari *dataset* ini dapat dilihat pada 0 di bawah yang menunjukkan citra paru-paru terpapar COVID-19, kondisi normal, dan terpapar Pneumonia.



Gambar 1 Citra paru-paru yang (1) terpapar COVID-19, (2) kondisi normal, (3) terpapar pneumonia (YUDISTIRA, WIDODO, & RAHAYUDI, 2020)

Ada 2 proses tahapan *preprocessing* yang dilakukan dalam penelitian ini, yaitu normalisasi dan augmentasi data. Normalisasi data adalah salah satu proses pengolahan data yang sangat penting untuk membuat nilai data berada dalam suatu rentang tertentu dengan tujuan membantu proses pelatihan menjadi jauh lebih cepat. Augmentasi data adalah

proses pengolahan data juga yang berguna untuk memanipulasi data tanpa kehilangan esensi data tersebut. Hasil dari proses augmentasi adalah sejumlah variasi data tambahan yang dapat mengoptimalkan performa pelatihan dari model *deep learning* (Wang & 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 (*brightness, saturation, hue*), fungsi *RandomHorizontalFlip* atau rotasi.

2.2 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 dari *convolution layer*, ReLU (fungsi aktivasi) dan *pooling layer*, sedangkan pada tahap kedua terdiri dari *flatten, fully-connected layer*, dan hasil prediksi. Pada setiap bagian tahapan terdapat dua proses utama, yaitu *feed-forward* dan *backpropagation*.

Ada 2 model arsitektur dari CNN yang digunakan dalam penelitian ini yang bertujuan untuk merekonstruksi citra sinar-X COVID-19, yaitu model *AlbuNet* dan *ResNet*. Model *AlbuNet* merupakan modifikasi dari model *LinkedNet* dengan model *ResNet* sebagai versi dari proses *autoencoder* (SHVETS, IGLOVIKOV, RAKHLIN, & KALININ, 2018). *ResNet* atau *Residual Neural Network* 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* dikarenakan keterbatasan *hardware* dan waktu pengerjaan peneliti.

2.3 MixedSampleDataAugmentation

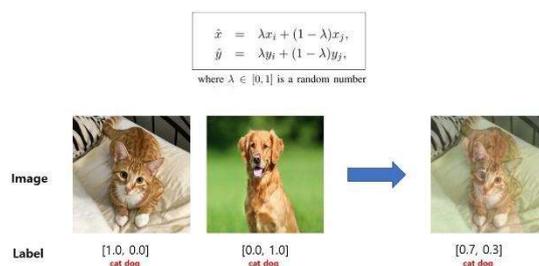
Dalam pelatihan model jaringan syaraf seringkali ditemukan fenomena *overfitting* di mana model terlalu cepat belajar pada data latih namun tidak dapat fokus ke suatu fitur penting tertentu. Hal ini menyebabkan setelah model konvergen terhadap data latih, model tidak dapat menggeneralisasi data baru di luar data latih (seperti data validasi maupun data uji) dengan baik. Masalah *overfitting* ini salah satunya dapat ditangani dengan cara menambah metode augmentasi terhadap data.

Mixed Sample Data Augmentation sendiri adalah metode augmentasi dengan menggabungkan fitur-fitur yang dimiliki beberapa data menjadi satu. Fitur-fitur yang dikombinasikan dari beberapa data

ini dapat membantu jaringan agar dapat fokus belajar ke fitur penting (lebih informatif) sehingga hasil pelatihan jaringan memiliki bobot yang lebih baik dan dapat menggeneralisasi data baru dengan lebih baik.

2.3.1 Mixup

Mixup merupakan salah satu solusi untuk mengatasi masalah *overfitting*. Cara kerja dari mixup yaitu dengan melatih jaringan syaraf dengan kombinasi pasangan fitur dan targetnya. Sehingga, mixup dapat mengatur jaringan syaraf untuk dapat mengenali perilaku linier sederhana dalam pelatihan. 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 jaringan syaraf yang canggih. Pada penelitian itu juga menemukan bahwa *mixup* dapat mengurangi pengenalan label yang tidak lengkap, dan menstabilkan pelatihan *adversarial generatif networks* (ZHANG, CISSE, DAUPHIN, & LOPEZ-PAZ, 2018). Ilustrasi hasil augmentasi *mixup* dapat dilihat pada 0.



Gambar 2. Ilustrasi Mixup (RUGERY, 2020)

2.3.2 CutMix

CutMix merupakan salah satu jenis augmentasi data image yang pada prosesnya melakukan *cut* dan *paste* pada bagian acak (piksel) pada sebuah data latih citra. Sebuah citra asli (*ground truth*) akan disatukan dengan citra yang lain agar menghasilkan gambar yang menjadi 1 antara 2 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 image yang lain secara proporsional agar suatu model bisa lebih fokus pada bagian yang tidak terlalu diskriminatif pada objek (SANGDOO, et al., 2019). CutMix dinilai dapat meningkatkan kemampuan *localization* dari objek yang diklasifikasikan, oleh karena itu CutMix cocok untuk beberapa kasus seperti deteksi objek. Ilustrasi hasil augmentasi Cutmix dapat dilihat pada 0.



Gambar 3. Ilustrasi Perbedaan Hasil Augmentasi Mixup, Cutout, dan Cutmix (SANGDOO, et al., 2019)

2.3.3 FMix

FMix adalah salah satu bentuk metode augmentasi di mana teknik *masking* yang dihasilkan adalah hasil dari *Fourier space* secara acak. Sehingga hasil *masking* berbentuk secara tidak teratur namun nilainya berkelanjutan dengan fitur-fitur di sekitarnya sehingga fitur tersebut tetap terjaga korelasinya dengan fitur di sekitarnya, khususnya untuk data yang berjenis citra di mana 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 0.

Grey-scale

Binary

Image 1

Image 2

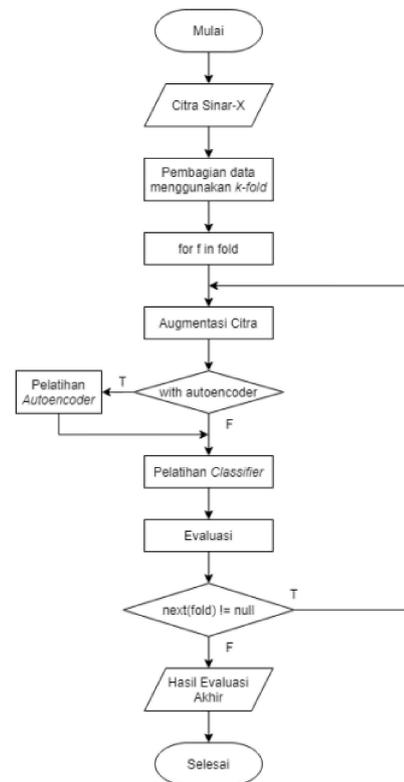
FMix



Gambar 4. Ilustrasi FMix (HARRIS, et al., 2020)

2.4 Tahap Pelatihan

Pada penelitian ini, pelatihan model dilakukan dengan dan tanpa arsitektur *Autoencoder* dengan pembagian dataset menggunakan metode *K-fold crossvalidation* sebelum dilakukannya pemrosesan untuk augmentasi, pelatihan, dan *classifier*. Ilustrasi tahapan pelatihan dapat dilihat pada 0.



Gambar 5. Flowchart Tahap Pelatihan

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

2.4.1 Tahap Pelatihan Autoencoder

Autoencoder adalah jenis arsitektur jaringan syaraf di mana terdiri dari bagian *encoder* dan *decoder*. Ukuran keluaran dari *encoder* umumnya lebih kecil dari ukuran masukannya, sedangkan ukuran keluaran pada *decoder* umumnya lebih besar dari ukuran masukannya. Pada arsitektur *autoencoder* ukuran masukannya sama dengan ukuran keluarannya. Dalam penelitian ini, kami menggunakan jenis *task* rekonstruksi citra untuk tahap pelatihan *autoencoder*. Pembelajaran rekonstruksi citra adalah pelatihan yang bertujuan untuk mempelajari data masukan dan

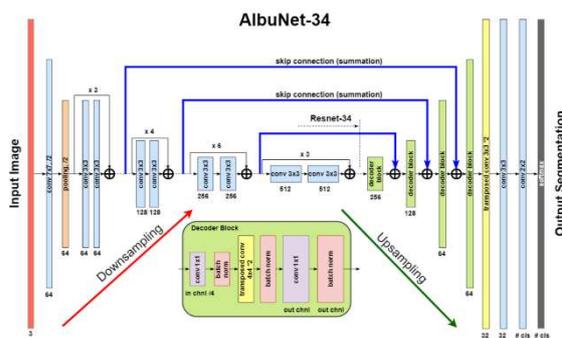
merekonstruksi terhadap data masukan tersebut sebagai pengurangan dimensi fitur. Pada penelitian ini, kami menggunakan arsitektur *AlbuNet* sebagai *autoencoder* yang terdiri dari lapisan sebagai berikut.

- 1) Lapisan *input*: lapisan data citra dengan parameter ditentukan oleh ukuran data masuk citra.
- 2) 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 0.

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 <i>max pooling</i> , stride 2, padding 1
conv3	28x28	
conv4	14x14	
conv5	7x7	
decoder1	14x14	
decoder2	28x28	
decoder3	56x56	
decoder4	112x112	
decoder5	224x224	

Ilustrasi secara keseluruhan dari arsitektur *AlbuNet* dapat dilihat pada 0.

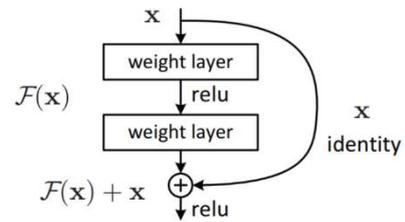


Gambar 6 Ilustrasi Arsitektur *AlbuNet* (SHVETS, IGLOVIKOV, RAKHLIN, & KALININ, 2018)

2.4.2 Tahap Pelatihan *Classifier*

Pelatihan pada tahap ini adalah pelatihan akhir secara *supervised* setelah pelatihan *autoencoder*. Pada pelatihan ini, hanya menggunakan bagian *encoders* saja dari *autoencoder* untuk mengklasifikasikan data. 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, ZHANG, REN, & SUN,

2015). Ilustrasi dari *residual connection* pada arsitektur *ResNet-18* dapat dilihat pada 0.



Gambar 7 Ilustrasi Arsitektur *ResNet* (HE, ZHANG, REN, & SUN, 2015)

2.5 Optimasi Adam

Adam merupakan algoritme optimasi gabungan dari *RMSProp* dan *Stochastic Gradient Descent* (SGD) dengan Momentum. Secara umum, algoritme ini menyelesaikan masalah lamanya konvergen sebuah model pada pelatihan. Penyelesaian dilakukan dengan menambahkan estimasi momentum pertama dan kedua untuk mengatur besarnya *learning rate* dari perubahan gradien sebelumnya untuk setiap bobot pada jaringan. Hal ini yang membuat Adam sedikit berbeda dengan *RMSProp*, dimana jika *RMSProp* mengadaptasi *learning rate* berdasarkan rata-rata dari perubahan gradien, Adam menghitungnya untuk setiap bobot. Penambahan ini dapat membantu jaringan untuk belajar dan mencapai konvergen lebih cepat serta mendapatkan akurasi yang tidak jauh berbeda dengan metode SGD klasik (KINGMA & BA, 2015).

3 HASIL DAN PEMBAHASAN

Pada penelitian ini kami melakukan percobaan untuk menerapkan *Autoencoder* sebagai *pre-training* dalam kasus klasifikasi citra sinar-X dada yang mempunyai 3 kategori, yaitu normal, pneumonia, dan COVID-19. Sebelumnya kami telah melatih model pembelajaran mendalam (*deep learning*) *AlbuNet* yang menggunakan *Resnet-18* sebagai *encoder* dengan *batch size* sebesar 256, *learning rate* sebesar 1×10^{-4} , dan Adam sebagai optimizer.

Untuk menguji model tersebut, dilakukan percobaan menggunakan validasi silang 5 bagian (*5-fold crossvalidation*). Pada setiap percobaan tersebut menggunakan perbandingan data latih dan data uji dalam setiap percobaan adalah sebesar 80:20. Salah satu hambatan dalam menerapkan metode pembelajaran mendalam adalah data yang digunakan harus banyak. Karena banyaknya data berbanding lurus dengan akurasi yang dihasilkan. Salah satu cara untuk mengatasinya yaitu kami menerapkan proses augmentasi citra dalam data agar lebih bervariasi tanpa harus menambah citra yang baru dengan tujuan tetap mempertahankan fitur kunci dalam data. Dalam penelitian ini kami menerapkan augmentasi *rotate*, balik

(horizontal flip), dan pengaturan warna (saturation, brightness, hue). Namun dalam penerapannya, kami mendapatkan hasil bahwa akurasi model akan mengalami kenaikan terbesar jika menerapkan gabungan dari tipe augmentasi rotate dan saturation seperti yang terlihat pada 0.

Tabel2 Hasil EksplorasiAugmentasi

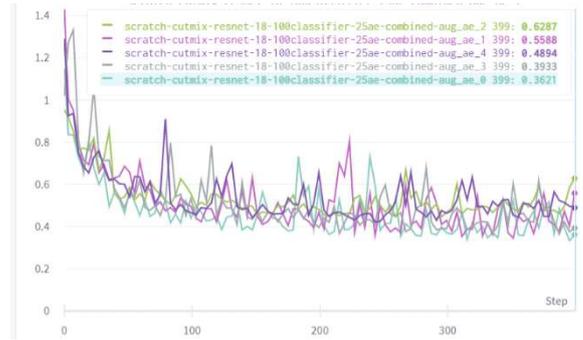
H.Flip	Bright 0.25	Saturation 0.25	Hue 0.1	Rotate 15°	Acc
					0.7973
				✓	0.8124
			✓		0.7902
		✓			0.8036
✓	✓				0.7724
		✓		✓	0.7876
				✓	0.8196*

Dikarenakan bertambah kompleksnya metode augmentasi yang digunakan pada percobaan terakhir, maka khusus pada percobaan tersebut kami menaikkan epoch-nya dari 25 menjadi 50. Selain augmentasi, kami juga melakukan normalisasi pada data menggunakan nilai rata-rata dan standar deviasi yang diambil dari data latih tiap fold cross validation.

Tabel3 Hasil EksplorasiMixed Sample Data Augmentation (MSDA)

Metode	Non-MSDA	Mix up	Cut Mix	FMix	Acc
Bobotawalrandom	✓				0.8116
		✓			0.7369
			✓		0.8027
				✓	0.8089
Bobotawalhasilautoencoder	✓				0.8133
		✓			0.7627
			✓		0.8196
				✓	0.8133

Kami juga melakukan eksplorasi pada data dengan menerapkan metode Mixed Sample Data Augmentation(MSDA) untuk melokalisir fitur-fitur yang terdapat pada data dengan menggunakan 100 epoch. Pada eksplorasi ini mendapatkan hasil bahwa akurasi terbesar yaitu dengan menggunakan MSDA jenis CutMixseperti yang terlihat pada0.Pada hasil tersebut juga dapat membuktikan bahwa metodepre-trainingdengan autoencodermenunjukkan 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 0,48646. Grafik nilai loss dan akurasi pada tiap foldselama pelatihan secara berturut-turut dapat dilihat0 dan 0.



Gambar 8.Grafikloss terhadap data validasiselama pelatihan dengan autoencoder sebagai pretraining dengan metode augmentasi Cutmix



Gambar 9Grafikakurasi terhadap data validasiselama pelatihan dengan autoencoder sebagai pretraining dengan metode augmentasi Cutmix

Tabel4Confusion Matrix AlbuNet-18 + autoencoder + Cutmix – 5-fold cross validation

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

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 0 juga menunjukkan bahwa citra sinar-X pada kategori normal dan pneumonia memiliki kemiripan pada pola data, sedangkan pada kategori COVID-19 mempunyai pola tersendiri.

Tabel5Tabelperhitunganmetrikshasilpengujian

Kelas	Precision	Recall	F1-score
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 0. 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.

4 KESIMPULAN

Hasil eksperimen yang telah dilakukan terhadap metode augmentasi gabungan antarm manipulasi warna pada *channel saturation* dan pemutaran citra menunjukkan peningkatan akurasi mencapai 2,23% terhadap *baseline* yang dilatih tanpa menggunakan metode augmentasi. Selain itu, dalam eksperimen penggunaan *Mixed Sample Data Augmentation* (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* dengan peningkatan performa sekitar 0,17% hingga 2,58%.

DAFTAR PUSTAKA

- ABBAS, A., ABDELSAMEA, M. M., & GABER, M. M. (2021). Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*, 854-864. doi:https://doi.org/10.1007/s10489-020-01829-7
- DAI, W.-C., ZHANG, H.-W., YU, J., XU, H.-J., CHEN, H., LUO, S.-P., . . . LIN, F. (2020). CT Imaging and Differential Diagnosis of COVID-19. *Canadian Association of Radiologists Journal*, 71(2), 195-200. doi:https://doi.org/10.1177/0846537120913033
- DEBRABATA, D., KUMAR, R., AISHIK, B., D. JUDE, H., DEEPAK, G., ASHISH, K., & OSCAR, C. (2020). Early diagnosis of COVID-19-affected patients based on X-ray and computed tomography images using deep learning algorithm. *Springer-Verlag GmbH Germany, part of Springer Nature 2020*, 9. doi:https://doi.org/10.1007/s00500-020-05275-y
- HARRIS, E., MARCU, A., PAINTER, M., NIRANJAN, M., PRÜGEL-BENNET, A., & HARE, J. (2020). FMix: Enhancing Mixed Sample Data Augmentation. *Vision, Learning, and Control Group*. Retrieved from https://www.researchgate.net/publication/339551062_FMix_Enhancing_Mixed_Sample_Data_Augmentation
- HE, K., ZHANG, X., REN, S., & SUN, J. (2015). Deep Residual Learning for Image Recognition. doi:https://doi.org/10.1109/CVPR.2016.90
- HUANG, C., WANG, Y., LI, X., REN, L., ZHAO, J., HU, Y., & ZHANG, L. (2020). Clinical Features of Patients Infected with 2019 Novel Coronavirus in Wuhan, China. 395, 10. doi:https://doi.org/10.1016/S0140-6736(20)30183-5
- KEMENTERIAN KESEHATAN REPUBLIK INDONESIA. (2020). *Pedoman Pencegahan dan Pengendalian Coronavirus Disease (COVID19)* (3rd ed.). Jakarta.
- KHAN, A. I., SHAH, J. L., & BHAT, M. M. (2020). CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *Elsevier*, 9. doi:https://doi.org/10.1016/j.cmpb.2020.105581
- KINGMA, D. P., & BA, J. (2015). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1-15. Retrieved from <https://arxiv.org/abs/1412.6980>
- LI, D., FU, Z., & XU, J. (2020). Stacked-autoencoder-based model for COVID-19 diagnosis on CT images. *Applied Intelligence*. doi:https://doi.org/10.1007/s10489-020-02002-w
- MINAEE, S., KAFIEH, R., SONKA, M., YAZDANI, S., & JAMALIPOUR, G. S. (2020). Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Elsevier*, 65, 9. doi:https://doi.org/10.1016/j.media.2020.101794
- OZTURK, T., TALO, M., YILDIRIM, E. A., BALOGLU, U. B., YILDIRIM, O., & ACHARYA, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Elsevier Public Health Emergency Collection*. doi:https://doi.org/10.1016/j.compbiomed.2020.103792
- PANWAR, H., GUPTA, P., SIDDIQUI, M. K., MENENDEZ, R. M., & SINGH, V. (2020). Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Elsevier*, 9. doi:https://doi.org/10.1016/j.chaos.2020.109944

- RUGERY, P. (2020, September 8). *Explanation of YOLO V4 a one stage detector*. Retrieved from *Becoming Human: Artificial Intelligence Magazine*: <https://becominghuman.ai/explaining-yolov4-a-one-stage-detector-cdac0826cbd7>
- SALAMEH, J., LEEFLANG, M., HOOFT, L., & ISLAM, N. (2020). Thoracic imaging tests for the diagnosis of COVID-19. In *Thoracic imaging tests for the diagnosis of COVID-19* (p. 97). Cochrane Library. doi:<https://doi.org/10.1002/14651858.CD013639.pub3>
- SANGDOO, Y., DONGYOON, H., JUNSUK, C., SEONG, J. O., YOUNGJOON, Y., & SANGHYUK, C. (2019). CutMix : Regularization Strategy to Train Strong Classifiers with Localizable Features. 1-14. doi:<https://doi.org/10.1109/iccv.2019.00612>
- SHVETS, A., IGLOVIKOV, V., RAKHLIN, A., & KALININ, A. A. (2018). Angiodysplasia Detection and Localization Using Deep Convolutional Neural Networks. *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 612-617. doi:<https://doi.org/10.1109/ICMLA.2018.00098>
- TARESH, M., ZHU, N., & ALI, T. A. (2020). Transfer learning to detect COVID-19 automatically from X-ray images, using convolutional neural networks. *medRxiv - Radiology and Imaging*. doi:10.1101/2020.08.25.20182170
- TURKOGLU, M. (2021). COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Artificial Intelligence Applications for COVID-19, Detection, Control, Prediction, and Diagnosis*, 1213–1226. doi:<https://doi.org/10.1007/s10489-020-01888-w>
- WORLD HEALTH ORGANIZATION. (2020). *World Health Organization*. Retrieved December 6, 2020, from <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/question-and-answers-hub/q-a-detail/coronavirus-disease-covid-19>
- YUDISTIRA, N., WIDODO, A. W., & RAHAYUDI, B. (2020). Deteksi COVID-19 Pada Citra Sinar-X Dada Menggunakan Deep Learning Yang Efisien. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 1289-1296. doi:<https://doi.org/10.25126/jtiik.2020763651>
- ZHANG, H., CISSE, M., DAUPHIN, Y. N., & LOPEZ-PAZ, D. (2018). mixup: BEYOND EMPIRICAL RISK MINIMIZATION. *Arxiv*. Retrieved from <https://arxiv.org/abs/1710.09412>