

Klasifikasi Penyakit Pneumonia Dan Covid-19 Berbasis Citra X-Ray Menggunakan Arsitektur *Deep Residual Network*

Classification Of Pneumonia And Covid-19 Based On X-Ray Images Using The Deep Residual Network Architecture

1st Prayogi Pangersa Illahi
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

prayogipangersa@student.telkomu
niversity.ac.id

2nd Hilman Fauzi
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

hilmanfauzisp@telkomuniversity.
ac.id

3rd Thomhert Suprpto Siadari
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

thomhert@telkomuniversity.ac.id

Abstrak—Pneumonia dan COVID-19 merupakan jenis penyakit yang dapat menginfeksi paru-paru dan bahkan menyebabkan kematian. Kedua jenis penyakit yang hampir mirip sehingga menjadi sulit untuk dibedakan. Terdapat berbagai metode untuk mendiagnosis penyakit pneumonia dan COVID-19. Salah satunya adalah dengan melihat hasil citra X-Ray. Dalam prosesnya dibutuhkan sistem yang otomatis dan akurat. Pada penelitian ini *deep learning* dengan model arsitektur *residual network* diimplementasikan ke dalam sistem untuk mengklasifikasikan data citra X-Ray menjadi tiga kelas, yaitu: Normal, Pneumonia, dan COVID-19. Ketiga data tersebut dilakukan tahapan *preprocessing resize* dan *CLAHE*. Total dataset yang digunakan untuk pelatihan, dan validasi, yaitu sebanyak 3097 citra dan tes sebanyak 233 citra X-Ray. Terdiri dari 1032 citra X-Ray pneumonia, 1032 citra X-Ray positif COVID-19, serta 1033 citra X-Ray normal. Penelitian dilakukan dengan melatih model ResNet-34, ResNet-50, dan ResNet-101. Dengan menggunakan *optimizer* Adam, Adamax, Nadam, dan SGD. Dari semua eksperimen, hasil terbaik didapatkan oleh model ResNet-101 menggunakan *optimizer* Adam, dengan akurasi validasi sebesar 91,2%. Usulan metode ini dievaluasi menggunakan presisi, *recall*, *F1-score*, dengan hasil masing-masing sebesar 0.81, 0.79, 0.79, dan akurasi test terbaik sebesar 79,91%.

Kata Kunci—pneumonia, COVID-19, citra x-ray, *deep learning*, resnet

Abstract—Pneumonia and COVID-19 are types of diseases that can infect the lungs and even cause death. The two types of disease are so similar that it becomes difficult to distinguish. There are various methods for

diagnosing pneumonia and COVID-19. One of them is by looking at the results of X-Ray images. In the process, an automated and accurate system is needed. In this study, deep learning with a residual network architecture model is implemented into the system to classify X-Ray image data into three classes, namely: Normal, Pneumonia, and COVID-19. The three data are preprocessing resize and CLAHE stages. The total dataset used for training and validation is 3097 images and test is 233 X-Ray images. Consisting of 1032 X-Ray images of pneumonia, 1032 X-Ray images positive for COVID-19, and 1033 normal X-Ray images. The research was conducted by training the ResNet-34, ResNet-50, and ResNet-101 models. By using optimizer Adam, Adamax, Nadam, and SGD. From all experiments, the best results were obtained by the ResNet-101 model using the Adam optimizer, with a validation accuracy of 91.2%. The proposed method was evaluated using precision, recall, F1-score, with the results of respectively 0.81, 0.79, 0.79, and the best test accuracy of 79.91%.

Keywords—pneumonia, COVID-19, citra x-ray, *deep learning*, resnet

I. PENDAHULUAN

Paru-paru merupakan organ tubuh yang mengatur sistem pernapasan dan berfungsi sebagai tempat bertukarnya oksigen dari udara dengan karbon dioksida dari darah. Tetapi jika fungsi paru-paru mengalami gangguan atau penyakit, maka sistem pernapasan tidak dapat bekerja dengan baik [1]. Penyakit paru-paru yang paling umum diderita oleh manusia adalah infeksi atau peradangan. Infeksi

paru-paru diantaranya Pneumonia dan COVID-19. Pneumonia disebabkan oleh mikroorganisme yang meliputi bakteri, jamur, dan virus. Sedangkan COVID-19 disebabkan oleh virus SARS-CoV-2 [2]. Pada tahun 2017, lebih dari 1 juta orang dirawat di rumah sakit karena pneumonia dan sekitar 50.000 orang meninggal karena penyakit ini setiap tahun di Amerika Serikat [3]. Sedangkan, pada kasus COVID-19 yang telah menyebar hampir ke seluruh negara di dunia. Hingga 31 Maret 2021, di Indonesia tercatat sebanyak 1.511.712 orang terkonfirmasi positif COVID-19. Dengan angka kematian mencapai 40.858 dan 1.348.330 pasien telah dinyatakan sembuh dari penyakit tersebut [4].

Terdapat beberapa cara untuk melakukan diagnosis pada penyakit pneumonia, diantaranya menggunakan MRI (*magnetic resonance imaging*), Citra X-Ray, dan CT (*computed tomography*). Diantara banyak cara diagnosis tersebut, citra X-Ray merupakan cara yang dinilai paling umum digunakan dikarenakan mudah dan biayanya murah [5]. Penyakit pneumonia dan COVID-19 sama-sama dapat dideteksi dengan analisa citra X-Ray paru-paru. Temuan kedua penyakit tersebut ditandai dengan konsolidasi yaitu gambaran citra X-Ray yang tampak putih atau berawan, disertai *ground glass opacity* yaitu bercak atau bintik putih yang buram dan menggumpal [6].

Beberapa penelitian telah dilakukan dalam mengklasifikasikan penyakit pneumonia dan COVID-19 menggunakan *deep learning* dengan data citra X-Ray. Pada penelitian [7] dua model *convolutional neural network* digunakan yaitu, Xception dan VGG-16 untuk mendiagnosis pneumonia. Hasil pengujian yang dilakukan pada penelitian tersebut menunjukkan bahwa VGG-16 *network* melebihi Xception *network* dengan akurasi masing-masing 87% dan 82%. Namun, Xception *network* mencapai hasil yang lebih baik dalam mendeteksi kasus pneumonia. Hasilnya, dapat disimpulkan bahwa setiap model memiliki kemampuan khusus pada kumpulan data yang sama. Pada penelitian [8] dua model *convolutional neural network* digunakan yaitu, CNNet dan ResNet yang digunakan untuk mengklasifikasikan citra X-Ray paru-paru dengan penyakit pneumonia, COVID-19, dan normal. Dengan mengatur dataset ke dalam tiga folder (pelatihan 60%, tes 20%, validasi 20%) yang berisi subfolder untuk setiap kategori gambar (300 gambar COVID-19, 350 normal, dan 350 gambar pneumonia virus). Berdasarkan pengujian yang telah dilakukan, akurasi model arsitektur ResNet dan CNNet masing-masing adalah 97,61% dan 94,28%. Didapatkan bahwa performa model ResNet lebih baik daripada model CNNet dalam mengklasifikasikan COVID-19 dan pneumonia.

Terdapat berbagai macam penelitian untuk melakukan klasifikasi penyakit pneumonia dan COVID-19 berbasis citra X-Ray. Namun, belum ada penelitian sebelumnya yang mengklasifikasikan

penyakit pneumonia dan COVID-19 berbasis citra X-Ray menggunakan model arsitektur *deep residual network*. Oleh karena itu, pada tugas akhir ini akan dilakukan penelitian dengan model arsitektur *deep residual network* memakai dataset citra X-Ray paru-paru dengan menambahkan tahap *preprocessing* dan pengaruh dari model ResNet, *optimizer*, dengan *learning rate* yang sama dalam membantu mempercepat diagnosis penyakit pneumonia dan COVID-19 berbasis citra X-Ray.

II. KAJIAN TEORI

A. Deep Learning

Deep learning merupakan subbidang dari *machine learning*. Pada *deep learning*, mesin memiliki kemampuan dalam memahami berbagai macam data dengan jumlah layer dan jaringan yang dalam (*deep*) atau sangat banyak. Layer-layer ini biasanya diatur secara berurutan dan terdiri dari layer transformasi non linear dari data input untuk menghasilkan *output*. Sehingga, representasi dari satu layer (dimulai dengan input data) dimasukkan ke dalam layer berikutnya dan diubah menjadi representasi yang lebih abstrak. Fakta di lapangan telah membuktikan banyak sekali kemajuan yang mencolok dalam kemampuan mesin untuk memahami dan memanipulasi data, termasuk *images*, *language*, dan *speech* [9]. Berdasarkan kemampuannya, *deep learning* terbagi menjadi beberapa kategori, diantaranya *supervised learning*, (misal: klasifikasi) dan *unsupervised learning* (misal: analisis pola). Selain itu, ada juga kategori lain dari cara pembelajaran lain mengenai *deep learning* yang disebut dengan *reinforcement learning* atau *deep reinforcement learning* [10].

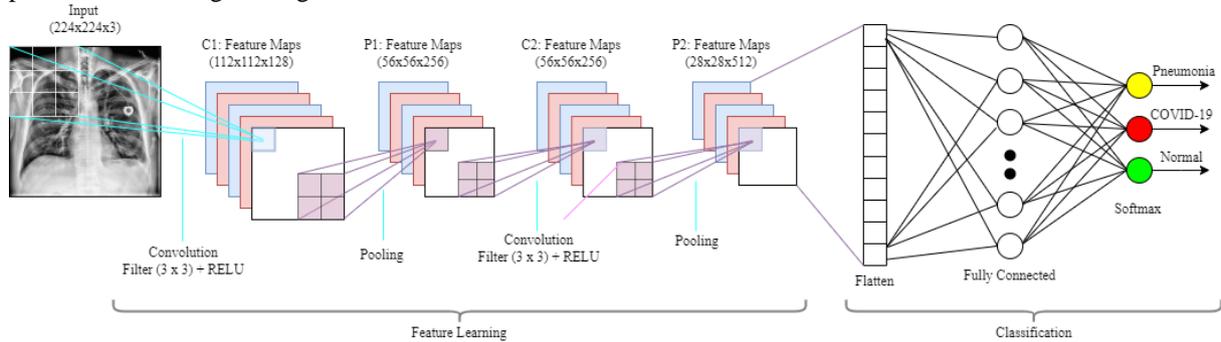
B. Convolutional Neural Network

CNN (*Convolutional Neural Network*) atau bisa disebut juga dengan ConvNet, memiliki arsitektur *feed-forward* yang dalam dan memiliki kemampuan luar biasa untuk menggeneralisasi dengan cara yang lebih baik [11]. Juga dapat mempelajari fitur yang sangat abstrak dari objek khususnya data spasial dan dapat mengidentifikasinya secara lebih efisien. Model CNN terdiri dari serangkaian lapisan pemrosesan terbatas yang dapat mempelajari berbagai fitur data input (misalnya gambar) dengan berbagai tingkat abstraksi [12].

Convolutional Neural Network terdiri dari beberapa layer, terlihat pada **Gambar 1**. Tahap pertama yang dilakukan yaitu, CNN mengambil nilai multidimensi atau piksel dari input gambar dan mengubahnya melewati *convolutional layer*, tahap kedua dilanjutkan dengan fungsi aktivasi, yang umumnya memakai ReLU (*Rectifier Linear Unit*), tahap ketiga dilakukan proses *pooling* dalam *pooling layer*. Proses *pooling* dilakukan dengan berulang kali hingga didapat pola fitur yang mencukupi agar

dapat melanjutkannya menuju tahap keempat yaitu tahap *fully connected layer* serta dilakukan fungsi aktivasi memakai *softmax*, sehingga diperoleh nilai probabilitas masing-masing *class*. Penentuan kelas

dari data dilakukan dengan mengklasifikasikannya pada probabilitas tertinggi hal ini tentu saja bergantung pada nilai probabilitas [13].



GAMBAR 1. Arsitektur *Convolutional Neural Network* [14]

1. Convolutional Layer

Convolutional layer merupakan komponen terpenting dari setiap arsitektur CNN. Terdapat isi satu set kernel convolutional (juga disebut dengan filter), yang melakukan proses konvolusi dengan gambar input untuk menghasilkan output peta fitur. Sehingga, setiap neuron dari satu layer terhubung dengan setiap neuron dari layer berikutnya [12].

2. Pooling Layer

Pooling layer digunakan untuk mengambil peta fitur ukuran lebih besar dan mengecilkannya ke peta fitur berukuran lebih kecil dengan maksud untuk mengurangi nilai parameter dalam proses aktivasi. Ada berbagai jenis teknik pooling yang digunakan dalam berbagai pooling layer seperti *max pooling*, dan *average pooling*. *Max pooling* adalah teknik pooling dengan mengambil nilai maksimum. Sedangkan *average pooling* merupakan teknik pooling dengan mengambil nilai rata-rata [12].

3. Fully-Connected Layer

Fully-connected layer merupakan *layer* terakhir, di mana setiap neuron di dalam suatu *layer* terhubung penuh dengan setiap neuron dari *layer* sebelumnya maupun setelahnya. *Layer* terakhir dari *fully-connected layer* digunakan sebagai *output layer (classifier)* dari arsitektur CNN [12].

C. Residual Network

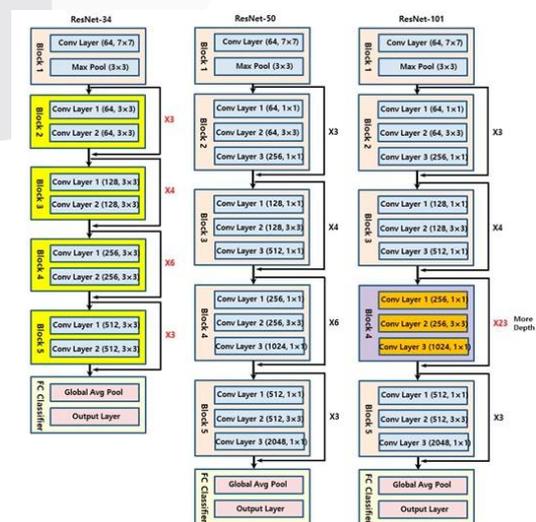
Residual network atau sering disebut sebagai ResNet dikembangkan dengan maksud untuk merancang *ultra-deep network* yang artinya tidak terdapat masalah *vanishing gradient* atau gradien yang hilang seperti pendahulunya. ResNet dikembangkan dengan beberapa *layer* yang berbeda seperti; 34, 50, 101, 152, dan bahkan 1202 [10]. Akan tetapi, pengujian pada penelitian ini hanya menggunakan ResNet dengan 34, 50, dan 101 layer. Struktur layer dari ketiga model ResNet diilustrasikan pada **Gambar 2**. Seperti yang sudah

dijelaskan sebelumnya bahwa CNN merupakan dasar dari arsitektur ResNet, dengan demikian pada ResNet-34, ResNet-50, dan ResNet-101 memiliki

komponen *layer* yang sama diantaranya, *convolutional layer*, *pooling layer*, dan *fully-connected (fc) layer* dengan penambahan *skip connection* pada setiap *layer* di beberapa *convolution layer*. Pada bagian akhir, ResNet menggunakan fungsi ReLU (*Rectifier Linear Unit*) dan fungsi *softmax* sebagai fungsi aktivasi. Fungsi ReLU ditampilkan pada Persamaan (1) dan fungsi *softmax* ditampilkan pada Persamaan (2).

$$f(x) = \max(0, x) \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \quad (1)$$

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (2)$$



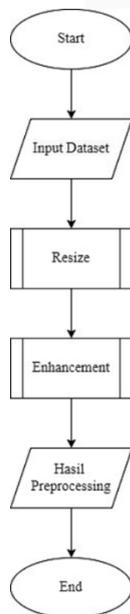
GAMBAR 2. Struktur *layer* ResNet-34, ResNet-50, ResNet-101

D. Pengumpulan Dataset

Bagian ini merupakan tahap pengambilan data sebelum melakukan pelatihan data. Dataset citra X-Ray pada penelitian ini, untuk data latih dan validasi diperoleh dari dataset citra X-Ray pneumonia yang sebelumnya telah digunakan pada penelitian yang dilakukan oleh Daniel S. Kermany, Michael Goldbaum, dkk., dan untuk data citra X-Ray COVID-19 diperoleh dari penelitian Muhammad E. H. Chowdhury, Tawsifur Rahman, Amith Khandakar, dkk. Dari keseluruhan dataset tersebut akan diambil masing-masing sebanyak 1032 citra X-Ray penyakit pneumonia, 1032 citra X-Ray positif COVID-19, serta 1033 citra X-Ray normal. Sedangkan, untuk data tes pneumonia dan COVID-19 sebanyak 233 citra X-Ray didapat dari penelitian Amanullah Ashraf, dkk.

E. Perancangan

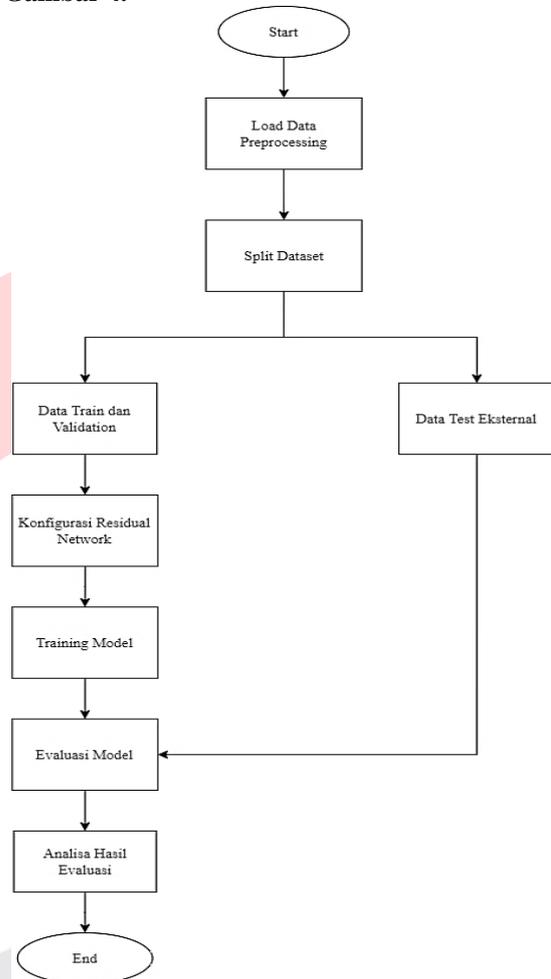
Setelah melakukan pengumpulan *dataset*, tahap selanjutnya adalah perancangan model sistem, pada bagian ini perancangan model sistem terdiri dari tahapan *preprocessing* hingga tahapan klasifikasi. *Preprocessing* merupakan tahapan atau metode pemrosesan dataset yang dilakukan sebelum melakukan pelatihan. *Preprocessing* memiliki fungsi untuk mempermudah sistem dalam mempelajari citra atau gambar yang akan dilakukan pelatihan. *Preprocessing* pada penelitian ini terdiri dari *resize* dan *enhancement*, dibawah ini merupakan flowchart dari proses tahapan *preprocessing* yang ditunjukkan pada **Gambar 3**.



GAMBAR 3. Flowchart preprocessing

Dalam *preprocessing* terdapat tahapan *resize*, yaitu mengubah ukuran citra ke dimensi yang lebih rendah dengan ukuran panjang 224 piksel dan lebar 224 piksel. Sedangkan untuk tahapan *enhancement*

menggunakan CLAHE merupakan tahapan yang digunakan untuk meningkatkan kontras dari citra X-Ray dengan parameternya, yaitu *clip limit*. Setelah *preprocessing*, selanjutnya melakukan tahapan klasifikasi. Tahapan klasifikasi yang berisi proses split data, konfigurasi ResNet, pelatihan model, serta evaluasi model. Seperti yang ditampilkan pada **Gambar 4**.



GAMBAR 4. Flowchart Klasifikasi

F. Evaluasi

Parameter yang digunakan untuk melakukan evaluasi model, yaitu menggunakan *confusion matrix* dengan tujuan untuk memudahkan dalam menganalisis data yang terdiri dari akurasi, presisi, *recall* dan *F1-score*. Indikator tingkat keberhasilan pada pengujian sistem ini menggunakan beberapa elemen diantaranya: TP (*true positive*), TN (*true negative*), FP (*false positive*), FN (*false negative*). TP merupakan data positif yang diprediksi dengan benar, TN merupakan data negatif yang diprediksi dengan benar, FP merupakan data negatif yang diprediksi sebagai data positif, dan FN merupakan data positif yang diprediksi sebagai data negatif [15].

TABEL 1. *Confusion Matrix*

		Kelas Sebenarnya	
		Positif	Negatif
Prediksi	Positif	TP (<i>True Positive</i>)	FP (<i>False Positive</i>)
	Negatif	FN (<i>False Negative</i>)	TN (<i>True Negative</i>)

Elemen-elemen tersebut dapat digunakan sebagai indikator untuk menghitung nilai akurasi, presisi, *recall*, dan *F1-score*. Akurasi diartikan sebagai perbandingan antara kelas yang diprediksi dengan benar terhadap total keseluruhan data yang ada. Presisi diartikan sebagai perbandingan antara kelas yang diprediksi dengan benar terhadap total data yang diprediksi positif. Recall diartikan sebagai *true positive* yang dilakukan perbandingan dengan total data yang benar terprediksi positif. Sedangkan, *F1-Score* diartikan sebagai gabungan rata-rata harmonik dari presisi dan *recall* [15]. Persamaan (3), (4), (5), (6), adalah formula dari akurasi, presisi, *recall*, dan *f1-score*.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$\text{Presisi} = \frac{TP}{TP + FP} \quad (4)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5)$$

$$F1 - \text{score} = \frac{2 * \text{Recall} * \text{Precision}}{\text{Recall} + \text{Precision}} \quad (6)$$

III. HASIL DAN PEMBAHASAN

Pada bagian ini akan menjelaskan hasil dan pembahasan secara terperinci. Dalam menjalankan simulasi klasifikasi penyakit pneumonia dan COVID-19, dataset dibagi menjadi tiga bagian, terdiri dari data latih, validasi, dan tes. Dengan pembagian masing-masingnya sebesar 80% data latih, 13% data validasi, dan 7% data tes yang berbeda sumber. Penelitian ini menggunakan *optimizer* Adam, dan AdaMax, Nadam, SGD, dan RMSprop, dengan menambahkan *preprocessing* *resize* dan CLAHE. Penelitian ini terdapat 3 skema pengujian yang dibagi berdasarkan model dengan arsitektur ResNet-34, model dengan arsitektur ResNet-50, serta model dengan arsitektur ResNet-101.

A. Pengaruh model ResNet-34

Hasil pengujian dengan model arsitektur ResNet-34 didapat hasil terbaiknya pada *optimizer* Nadam dengan nilai akurasi data latihnya sebesar 97,66% dan akurasi validasinya sebesar 90,05%.

Sedangkan, untuk nilai akurasi data tes terbaik didapat oleh *optimizer* Adam, yaitu sebesar 76,34%. Pada Tabel 2. merupakan hasil dari masing-masing *optimizer* yang terbagi menjadi tiga dataset latih, validasi, dan tes, dengan menggunakan model arsitektur ResNet-34.

TABEL 2. Hasil akurasi data latih, validasi, dan tes, menggunakan ResNet-34

Model		Akurasi %		
		Latih	Validasi	Tes
ResNet-34	Adam	97,39	88,43	76,34
	Adamax	97,47	88,89	73,66
	Nadam	97,66	90,05	72,32
	SGD	94,3	87,73	74,55
	RMSprop	95,69	86,11	75

B. Pengaruh model ResNet-50

Hasil pengujian dengan model arsitektur ResNet-50 didapat hasil terbaiknya pada *optimizer* RMSprop dengan nilai akurasi data latihnya sebesar 97,36%, akurasi validasinya sebesar 88,89%, dan nilai akurasi tesnya sebesar 77,23%. Tabel 3. merupakan hasil dari masing-masing *optimizer* yang terbagi menjadi tiga dataset latih, validasi, dan tes, dengan menggunakan model arsitektur ResNet-50.

TABEL 3. Hasil akurasi data latih, validasi, dan tes, menggunakan ResNet-50

Model		Akurasi %		
		Latih	Validasi	Tes
ResNet-50	Adam	95,54	86,61	70,54
	Adamax	90,29	82,87	73,66
	Nadam	96,6	87,04	75,45
	SGD	84,1	78,01	69,2
	RMSprop	97,36	88,89	77,23

C. Pengaruh model ResNet-101

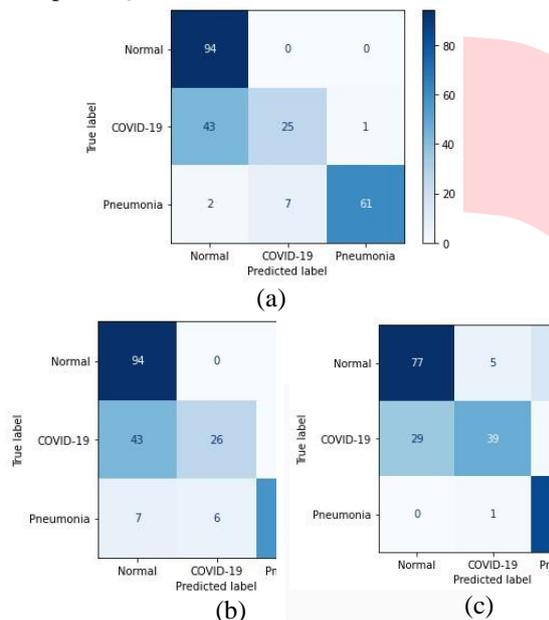
Hasil pengujian dengan model arsitektur ResNet-101 didapat hasil terbaiknya pada *optimizer* Adam dengan nilai akurasi validasinya sebesar 91,2%, dan nilai akurasi tesnya sebesar 79,91%. Sedangkan, untuk nilai akurasi data latih terbaik didapat oleh *optimizer* Adamax, yaitu sebesar 99,81%. Tabel 4. merupakan hasil dari masing-masing *optimizer* yang terbagi menjadi tiga dataset latih, validasi, dan tes, dengan menggunakan model arsitektur ResNet-50.

TABEL 4. Hasil akurasi data latih, validasi, dan tes, menggunakan ResNet-101

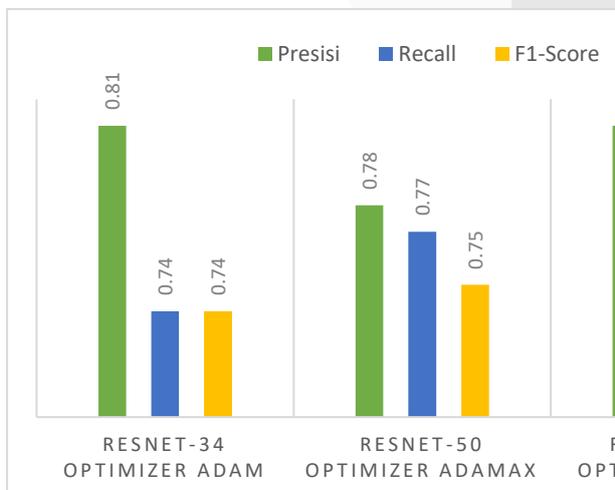
Model		Akurasi %		
		Latih	Validasi	Tes
ResNet-101	Adam	99,62	91,2	79,91
	Adamax	99,81	90,51	79,46
	Nadam	98,5	90,51	75,45
	SGD	94,3	85,88	73,66
	RMSprop	98,94	89,58	77,68

D. Evaluasi model

Hasil evaluasi model dengan prediksi dan klasifikasi terbaik menggunakan data tes didapatkan oleh *optimizer* Adam untuk ResNet-34, dan ResNet-101. Sedangkan untuk ResNet-50 hasil prediksi dan klasifikasi terbaik didapatkan oleh *optimizer* RMSprop. Seperti yang ditampilkan dengan *confusion matrix* pada **Gambar 5**. Hasil *confusion matrix* akan dilakukan evaluasi dengan menggunakan Persamaan (3), (4), (5) dan (6). Sehingga, didapat nilai rata-rata presisi, *recall*, dan *f1-score* dari masing-masing model arsitektur ResNet dengan *optimizer* terbaik. Seperti yang ditampilkan pada **Gambar 6**.



GAMBAR 5. Hasil *confusion matrix* (a) *optimizer* Adam dengan ResNet-34, (b) *optimizer* RMSprop dengan ResNet-50, (c) *optimizer* Adam dengan ResNet-101



GAMBAR 6. Rata-rata Presisi, *Recall*, dan *F1-Score* pada setiap ResNet dengan *optimizer* yang berbeda

IV. KESIMPULAN

Dari hasil pengujian dan analisa yang telah dilakukan, dapat disimpulkan bahwa metode CNN dengan model arsitektur *deep residual network* dapat digunakan untuk mengklasifikasikan penyakit pneumonia, COVID-19, serta normal melalui citra X-Ray paru-paru. Pada proses pengujiannya, penelitian ini menggunakan data tes yang berbeda sumber dengan data latih dan data validasi. *Optimizer* SGD merupakan *optimizer* yang paling stabil dan paling sedikit mengalami *overfitting* jika dilihat dari grafik proses pelatihannya. Meskipun hasil akurasi dari data latih, validasi, dan tesnya tidak sebaik dari *optimizer* lainnya. Hasil uji coba model dengan data validasi, performa terbaik didapat menggunakan arsitektur ResNet-101 dengan *optimizer* Adam. Dengan hasil validasi akurasi tertinggi yaitu 91,2% dan memiliki nilai *loss* paling rendah. Hasil evaluasi model dengan data tes didapatkan nilai tertingginya, yaitu akurasi 79,91%, presisi 0,81, *recall* 0,79, dan *f1-score* 0,79.

REFERENSI

- [1] M. A. Hariadi, L. S. Angreani dan A. S. Fatkhurrahman, "APLIKASI SEGMENTASI PARU-PARU," *Jurnal Ilmu Komputer dan Teknologi Informasi*, vol. 7, no. 1, pp. 5-8, 16 November 2015.
- [2] E. Kusumawardhani, *Mengenal Perbedaan Pneumonia COVID-19 dengan Pneumonia Oleh Sebab Lain*, Banjarmasin: Rumah Sakit Umum Daerah Ulin Banjarmasin, 2020, pp. 14-15.
- [3] P. Rajpurkar, J. Irvin, K. Zhu dan e. a. , "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," *Computer Vision and Pattern Recognition*, pp. 1-7, 2 Agustus 2017.
- [4] Z. Nabila, A. R. Isnain, P. dan Z. Abidin, "ANALISIS DATA MINING UNTUK CLUSTERING KASUS COVID-19," *Jurnal Teknologi dan Sistem Informasi (JTSI)*, vol. 2, no. 2, pp. 100-108, 21 September 2021.
- [5] Y. Li, Z. Zhang dan et al., "Accuracy of deep learning for automated detection of pneumonia using chest X-Ray images: A systematic review and meta-analysis," *Computers in Biology and Medicine*, vol. 123, pp. 1-8, 2020.
- [6] M. Nishio, S. Noguchi dan et al., "Automatic classification between COVID-19 pneumonia, non-COVID-19 pneumonia, and the healthy on chest X-ray image: combination of data augmentation methods," *Scientific Reports*, vol. 10, pp. 1-6, 2020.

- [7] E. Ayan dan H. M. Ünver, "Diagnosis of Pneumonia from Chest X-Ray Images Using Deep Learning," *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*, pp. 1-5, 2019.
- [8] A. Keles, M. B. Keles dan A. Keles, "COVID-19-CNNNet and COVID-19-ResNet: Diagnostic Inference Engines for Early Detection of COVID-19," *Cognitive Computation*, pp. 1-11, 2020.
- [9] A. Esteva, A. Robicquet, B. Ramsundar dan e. a. , "A guide to deep learning in healthcare," *Nature Medicine*, vol. 25, pp. 24-29, 5 Februari 2019.
- [10] M. Z. Alom, T. M. Taha, C. Yakopcic dan et al., "A State-of-the-Art Survey on Deep Learning Theory and Architectures," *Journal Electronics*, vol. 8, no. 3, pp. 1-67, 2019.
- [11] S. Indolia, A. K. Goswami, M. dan P. Asopa, "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach," *International Conference on Computational Intelligence and Data Science (ICCIDS 2018)*, vol. 132, pp. 679-688, 2018.
- [12] A. Ghosh, A. Sufian dan et al., "Fundamental Concepts of Convolutional Neural Network," *Recent Trends and Advances in Artificial Intelligence and Internet of Things*, vol. 172, pp. 519-567, 30 Agustus 2020.
- [13] P. Kamencay, M. Benco, T. Mizdos dan R. Radil, "A New Method for Face Recognition Using Convolutional Neural Network," *ADVANCES IN ELECTRICAL AND ELECTRONIC ENGINEERING*, vol. 15, no. 4, pp. 663-672, 2017.
- [14] C. . B. S. Maior, J. M. M. Santana, I. D. Lins dan M. J. C. Moura, "Convolutional neural network model based on radiological images to support COVID-19 diagnosis: Evaluating database biases," *PLoS ONE*, vol. 16, no. 3, pp. 1-25, 2021.
- [15] Y. S. Hariyani, S. Hadiyoso dan T. S. Siadari, "Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network," *Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 2, pp. 443-453, 2020.