

Klasifikasi COVID 19 dengan Metode EfficientNet Berdasarkan CT Scan Paru-Paru

Akhmad Irsyad^{1)*}, Islamiyah²⁾, Fakhmul Amal³⁾

Sistem Informasi, Universitas Mulawarman, Samarinda^{1,2,3}
akhmadirsyad@ft.unmul.ac.id^{1)*}, islamiyah@ft.unmul.ac.id²⁾, fakhmulamal@gmail.com³⁾

Abstrak

Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2) adalah virus penyebab Covid-19. Covid-19 adalah virus mematikan yang oleh Organisasi Kesehatan Dunia (WHO) ditetapkan sebagai pandemi karena penyebarannya yang cepat. Dua metode yang kini paling sering digunakan untuk mendeteksi Covid-19 adalah *Rapid Diagnostic Test (RDT)* dan *Real-Time Reverse Transcription Polymerase Chain Reaction (RT-PCR)*. Menemukan strategi baru yang cepat dan tepat sangat penting karena kedua strategi memiliki kelebihan dan kekurangan. Penggunaan CT scan untuk menemukan Covid-19 adalah salah satu metode yang direkomendasikan. Makalah ini merekomendasikan identifikasi Covid-19 pada gambar CT menggunakan EfficientNet B0 tampil lebih unggul dari model tanpa CLAHE. Untuk performa EfficientNet B0 dengan CLAHE, akurasi, F-measure, recall, dan precision adalah 91,95%, 92,06%, 92,43%, dan 91,69%..

Kata kunci: Covid-19, Klasifikasi, Deep Learning, EfficientNet

Abstract

[Classification of COVID 19 using the EfficientNet Method Based on Lung CT Scan] *Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2)* is the virus that causes Covid-19. Covid-19 is a deadly virus that the World Health Organization (WHO) has designated as a pandemic due to its rapid spread. The two methods that are now most often used to detect Covid-19 are the *Rapid Diagnostic Test (RDT)* and *Real-Time Reverse Transcription Polymerase Chain Reaction (RT-PCR)*. Finding a new strategy that is quick and precise is crucial since both strategies have benefits and drawbacks. The use of a CT scan to locate Covid-19 is one recommended method. This paper recommends identifying Covid-19 on CT images using EfficientNet B0 performs superior to the model without CLAHE. For the performance of EfficientNet B0 with CLAHE, accuracy, F-measure, recall, and precision are 91.95%, 92.06%, 92.43%, and 91.69%.

Keywords: Covid-19, Classification, Deep Learning, EfficientNet

1. PENDAHULUAN

Coronavirus disease 2019 (COVID-19) adalah penyakit disebabkan oleh virus *Severe Acute Respiratory Syndrome Coronavirus 2 (SARS-CoV-2)*, penyakit ini menyebar dengan cepat dan dapat menyebabkan kematian. Hingga Juni 2023 COVID-19 telah menyebabkan sekitar 6.808.056 kematian dari 161.778 kasus yang terinfeksi diseluruh Indonesia [1]. Selama fase awal penyakit ini ditandai dengan demam, batuk, dan kelelahan. Temuan menunjukkan bahwa virus COVID-19 menyebar dari orang ke orang. Orang yang terinfeksi memiliki masalah pernapasan serius dan perlu dirawat di unit perawatan intensif. Para pasien memiliki kondisi abnormal pada citra paru-paru hasil *Computed Tomography (CT)*. *CT scan* orang yang terinfeksi menunjukkan bahwa penyakit COVID-19 memiliki karakteristik sendiri. Dari beberapa karakteristik CT paru-paru pasien COVID-19 diantaranya adalah *Ground Glass Opacity (GGO)*, *pleural changes*, dan *consolidation*. Karena itu, para

ahli klinis membutuhkan citra CT paru untuk mendiagnosis COVID-19 pada fase awal [2].

Salah satu rintangan utama dalam mengendalikan penyebaran penyakit ini adalah cepatnya penularan dan kekurangan tes. Tes saat ini sebagian besar didasarkan pada *Real Time Polymerase Chain Reaction (RT-PCR)*. Kurangnya alat tes RT-PCR selama waktu puncak wabah COVID-19, menyebabkan banyak kasus yang dicurigai tidak dapat diuji dalam waktu cepat dan mereka terus menyebarkan penyakit kepada orang lain secara tidak sadar. Selain itu saat ini ada dua metode yang biasa digunakan dalam penanganan COVID-19, yaitu *Rapid Diagnostic Test (RDT)* dan *Real-Time Reverse Transcription Polymerase Chain Reaction (RT-PCT)*, RDT membutuhkan waktu singkat namun memiliki akurasi yang lebih rendah, dan RT-PCT yang memiliki akurasi lebih baik daripada RDT, tetapi membutuhkan waktu yang lama [3], [4]. Diperlukan metode alternatif yang membutuhkan waktu singkat dan akurasi tinggi. Salah satu metode yang ditawarkan

adalah dengan menggunakan citra CT yang telah digunakan oleh beberapa rumah sakit [5].

Perkembangan *computer vision* yang mendukung biomedik telah banyak berkembang seperti meningkatkan kualitas citra [6], segmentasi organ [7], dan klasifikasi tekstur organ [8], analisis *time series* [9], dan karakteristik tumor [10] adalah beberapa pengembangan *computer vision* dalam bidang biomedik. Citra medis CT scan dan X-ray paru-paru sangat penting untuk diagnosis COVID-19 otomatis. Beberapa rumah sakit terkemuka di dunia menggunakan algoritma *artificial intelligence* (AI) untuk mendiagnosis kasus COVID-19 dari CT scan atau Gambar X-ray [11].

Berikut adalah beberapa studi AI tentang diagnosis COVID-19. Studi yang dilakukan oleh Apostolopoulos dan Mpesiana (2020) menggunakan *dataset* Gambar sinar-X dari pasien dengan pneumonia bakteri yang umum ditemukan, penyakit COVID-19 yang dikonfirmasi, dan normal. Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja arsitektur jaringan saraf convolutional *state-of-the-art* yang diusulkan selama beberapa tahun terakhir untuk klasifikasi citra medis. Secara khusus, prosedur yang disebut *Transfer Learning* diadopsi. Dengan *transfer learning*, deteksi berbagai kelainan pada *dataset* citra medis merupakan target yang dapat dicapai. Kumpulan data yang digunakan dalam percobaan ini ada dua. Pertama, koleksi 1427 citra X-ray termasuk 224 citra dengan penyakit COVID-19 yang dikonfirmasi, 700 citra dengan *pneumonia* bakteri umum yang dikonfirmasi, dan 504 citra kondisi normal. Kedua, *dataset* termasuk 224 Gambar dengan penyakit COVID-19 yang dikonfirmasi, 714 citra dengan *pneumonia* bakteri dan virus yang dikonfirmasi, dan 504 citra dari kondisi normal. Data dikumpulkan dari citra X-ray yang tersedia di repositori medis publik. Hasil penelitian menunjukkan bahwa pembelajaran jauh dengan pencitraan sinar-X dapat mengekstraksi biomarker signifikan yang terkait dengan penyakit COVID-19, sedangkan akurasi, sensitivitas, dan spesifisitas terbaik yang diperoleh adalah masing-masing 96,78%, 98,66%, dan 96,46%[12].

X. Yang et al., (2020) melakukan penelitian dengan pengumpulan *dataset Computed Tomography* (CT) Covid-19, dan menggunakannya untuk dilatih menggunakan *machine learning*. CT scan adalah cara yang berguna untuk mendiagnosis pasien COVID-19 namun memiliki beberapa kesulitan dalam pengumpulan data karena masalah privasi, *dataset* CT COVID-19 yang tersedia secara publik sangat sulit diperoleh, yang menghambat penelitian dan pengembangan metode diagnosis COVID-19 yang didukung AI berdasarkan CT. Untuk mengatasi masalah ini, penelitian ini menghasilkan output *dataset* COVID-CT yang berisi 349 citra COVID-19 CT dari 216 pasien dan 463 non-COVID-19 CT, yang telah diuji dengan model deep learning VGG dimana hasil yang diperoleh berupa akurasi. Kegunaan *dataset* ini dikonfirmasi oleh ahli radiologi senior yang telah

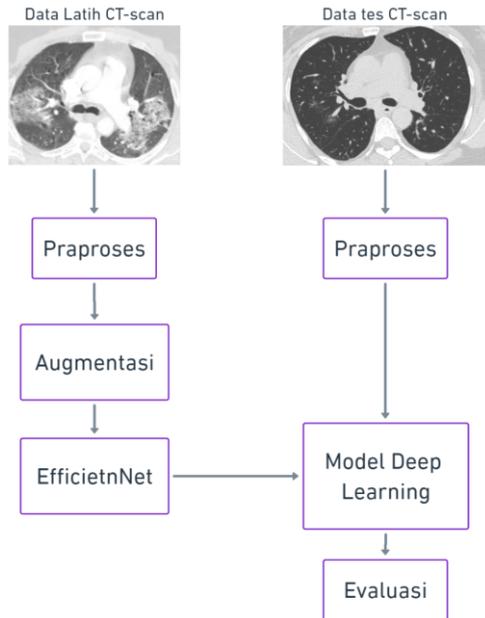
mendiagnosis dan merawat pasien COVID-19 sejak wabah pandemi ini. Penelitian ini juga melakukan studi eksperimental yang lebih lanjut menunjukkan bahwa *dataset* ini berguna untuk mengembangkan model diagnosis berbasis AI dari COVID-19. Dengan menggunakan *dataset* ini, penelitian ini mengembangkan metode diagnosis berdasarkan pembelajaran multi-tugas dan pembelajaran mandiri, yang mencapai F1 0.90, AUC 0.98, dan akurasi 0.89. Menurut ahli radiolog senior, model dengan kinerja seperti itu cukup baik untuk penggunaan klinis [5].

Dari beberapa penelitian terkait dapat disimpulkan *deep learning* dapat memiliki akurasi yang baik untuk melakukan klasifikasi COVID-19. Pada penelitian dilakukan uji coba mencoba untuk mengembangkan model untuk klasifikasi COVID-19 berdasarkan CT paru-paru menggunakan Arsitektur *EfficientNet B0*. *EfficientNet* adalah Arsitektur yang dikembangkan oleh Ming Xingdan Quoc pada tahun 2019. *EfficientNet* adalah metode yang dapat *scale up* semua dimensi kedalaman, lebar, dan resolusi secara seragam menggunakan koefisien gabungan yang sangat efektif [13]. Jaringan *EfficientNet* memiliki arsitektur dari B0 hingga B7, Jaringan *EfficientNet* memiliki jumlah blok MBConv yang berbeda. Saat beralih dari *EfficientNetB0* ke *EfficientNetB7*, kedalaman, lebar, resolusi, dan ukuran model terus meningkat dan akurasi juga ditingkatkan [14]. Berdasarkan penjelasan latar belakang, penelitian ini mengangkat masalah Klasifikasi Covid-19 berdasarkan CT scan paru-paru dengan metode *EfficientNet*.

Penelitian ini memiliki beberapa bagian dimulai dari bagian pendahuan yang berisi pembahasan latar belakang dilakukannya penelitian, lalu ada bagian bahan dan metode yang berisi data yang digunakan dalam penelitian dan metode yang digunakan dalam penelitian untuk melakukan penelitian mulai dari praproses, *efficientNet*, dan metode evaluasi model, bagian selanjutnya adalah hasil dan pembahasan berisi hasil dari penelitian dan kesimpulan yang diperoleh dari penelitian yang dilakukan

2. BAHAN DAN METODE

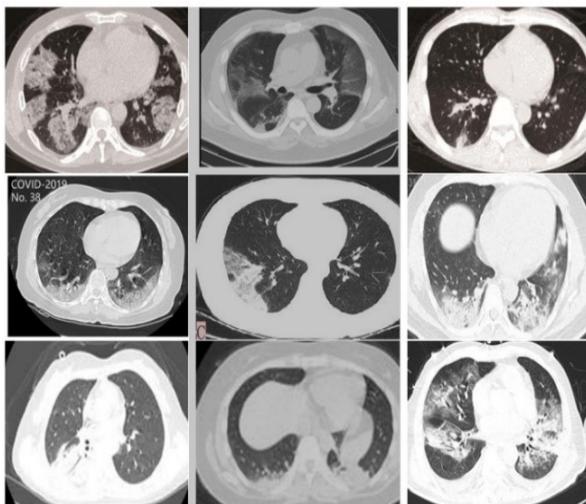
Penelitian ini dimulai dengan mengumpulkan data CT-scan paru-paru lalu data yang diperoleh dilakukan praproses, tujuan dilakukan praproses adalah untuk mengurangi noise yang ada pada gambar sehingga diperoleh hasil output yang lebih baik. Data yang telah di praproses selanjutnya dibagi menjadi data train dan data test. Nantinya data train akan digunakan augmentasi lalu dilakukan pelatihan model. Pada penelitian akan menggunakan arsitektur *EfficientNet B0* karena dari semua arsitektur *EfficientNet*, *EfficientNet B0* adalah yang paling simpel namun tetap memiliki kemampuan klasifikasi yang baik. Hasil model pelatihan model *EfficientNet B0* akan di uji coba dengan data test sehingga diperoleh hasil evaluasi dari model yang dibuat, untuk lebih jelas alur penelitian dapat dilihat pada Gambar 1.



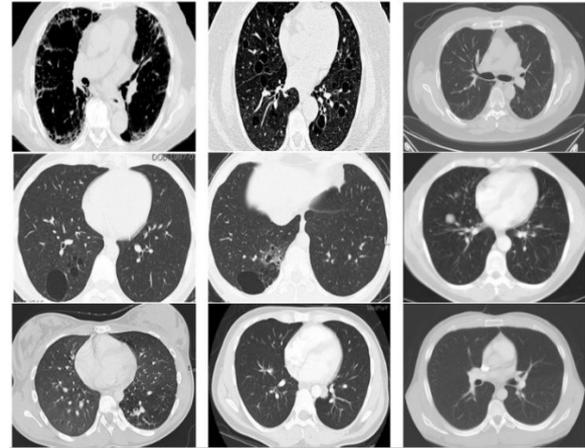
Gambar 1. Alur Penelitian.

2.1 Data

Dataset klasifikasi menggunakan dataset dari Soares et al. (2020), di mana terdapat 1230 CT scan normal dan 1252 CT scan COVID-19. Total citra adalah 2482 CT scan. Dataset diperoleh dari rumah sakit yang terletak di Sao Paulo, Brasil [15]. Dataset CT scan terdiri dari gambar dengan format jpg dan png. Ukuran dari tiap gambar berbeda-beda sehingga perlu dilakukan proses resize sebelum data di proses. Gambar 2 adalah contoh dari dataset CT COVID-19 dan Gambar 3 adalah contoh dataset CT non COVID-19. Seperti yang bisa dilihat pada CT scan paru-paru positif Covid-19 memiliki lesion sehingga tampak banyak corak berwarna putih. Dataset akan dibagi menjadi data train dan data test, dengan perbandingan 60% untuk data train, 20% data validasi, dan 60% data test. Data validasi digunakan digunakan untuk memberikan evaluasi selama proses pelatihan model.



Gambar 2. Contoh CT scan Covid-19 C



Gambar 3. Contoh CT scan negatif Covid-19.

2.2 Praproses

Praproses dimulai dengan mengubah ukuran dari semua gambar menjadi 224 x 224 pixel, karena ukuran awal dari setiap gambar berbeda sehingga perlu disamakan untuk mempermudah proses input ke arsitektur deep learning. proses selanjutnya adalah meningkatkan kualitas gambar dataset, pada penelitian yang dilakuakn menggunakan metode Contrast Limited Adaptive Histogram Equalization (CLAHE). CLAHE adalah salah satu metode untuk meningkatkan kualitas gambat dengan membagi gambar menjadi beberapa bagian dan melakukan perbaikan kontras per sub-gambar. CLAHE adalah perkembangan dari metode Adaptive Histogram Equalization (AHE), yang menjadi pembedanya adalah AHE melakukan perbaikan kontras pada satu gambar sedangkan CLAHE mebagi terlebih dahulu gambar menjadi beberapa bagian kecil. Adapun langkah-langkah pada proses CLAHE adalah sebagai berikut [16]:

1. Bagi gambar asli menjadi sub-gambar.
2. Hitung setiap histogram sub-gambar.
3. Klip setiap histogram sub-gambar.
4. Lakukan peningkatan dengan menginterpolasi pemetaan skala abu-abu

Kuantitas piksel dalam sub-gambar disesuaikan pada setiap nilai grayscale. Jumlah piksel rata-rata pada setiap nilai grayscale diberikan dalam persamaan 1:

$$N_{avg} = \frac{N_x \times N_y}{N_{gray}} \tag{1}$$

N_{CL} adalah jumlah skala abu-abu pada sub-gambar, dan adalah jumlah piksel sub-gambar masing-masing dalam dimensi X dan Y. Kemudian batas klip dari histogram dihitung dari persamaan 2:

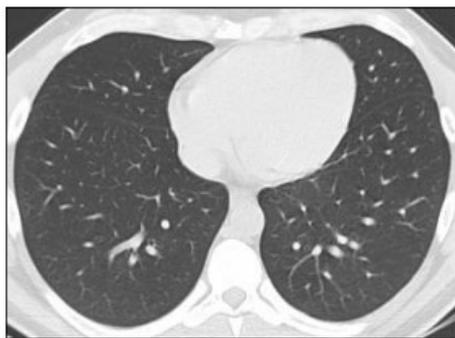
$$N_{CL} = N_{CLIP} \times N_{avg} \tag{2}$$

N_{CLIP} adalah nilai piksel rata-rata maksimum dari setiap skala keabuan pada sub-gambar. Piksel pada histogram pertama akan terpotong jika kuantitas piksel lebih menonjol dari jumlah piksel yang disesuaikan secara merata ke dalam setiap skala abu-abu (N_d)

dalam hal jumlah total piksel terpotong dijelaskan oleh persamaan 3:

$$N_d = \frac{N_{TC}}{N_{gray}} \quad (3)$$

Gambar 4 adalah contoh dari hasil praproses. Seperti yang bisa dilihat pada gambar (a) mempunyai kontras yang masih kurang sebab perbedaan warna masih kurang jelas, pada gambar (b) dapat dilihat bahwa perbedaan kontras gambar menjadi lebih baik sehingga perbedaan warna antara lesion dan paru-paru menjadi lebih jelas



(a)



(b)

Gambar 4. a) CT scan sebelum praproses CLAHE, (b) CT scan setelah praproses CLAHE.

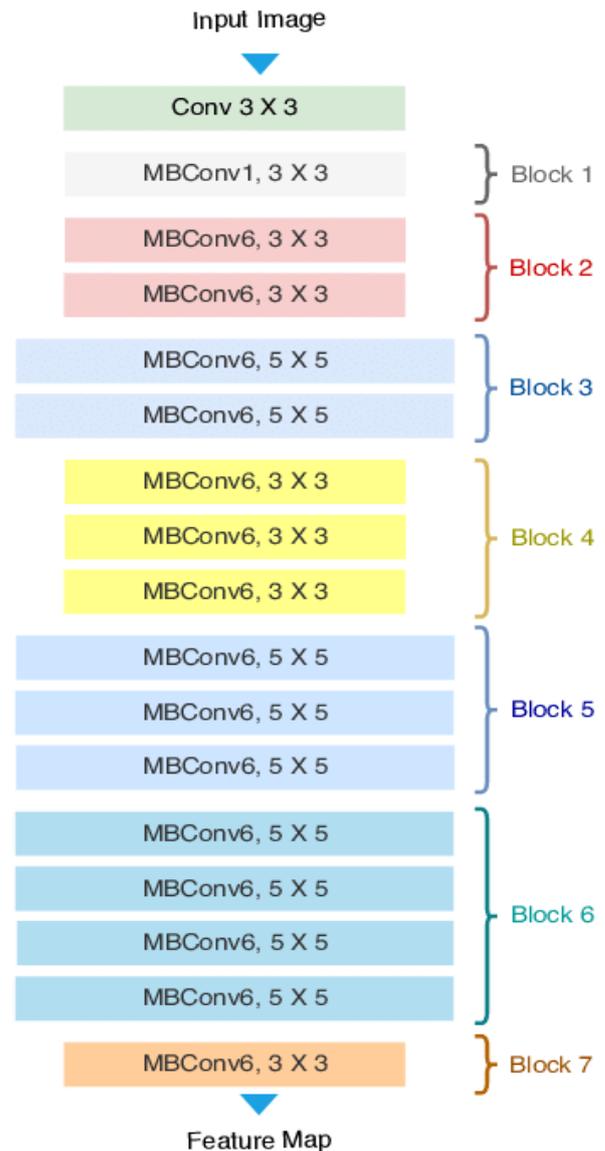
2.4 Augmentasi

Augmentasi data adalah metode yang digunakan untuk meningkatkan keragaman data yang tersedia untuk model pelatihan tanpa benar-benar mengumpulkan data baru [17]. Berikut adalah metode augmentasi yang digunakan pada penelitian: *Cropping* adalah metode augmentasi yang dilakukan dengan cara memangkas bagian dari gambar asli dan merubah ukuran gambar yang dipangkas ke resolusi tertentu. *Flipping* adalah metode augmentasi yang dilakukan dengan cara membalikan gambar secara horizontal maupun vertical. *Rotation* adalah metode augmentasi yang dilakukan dengan cara memutar gambar secara acak.

2.5 EfficientNet

Gambar 5 EfficientNet dikembangkan oleh Ming Xingdan Quoc pada tahun 2019. EfficientNet adalah metode yang dapat *scale up* semua dimensi kedalaman,

lebar, dan resolusi secara seragam menggunakan koefisien gabungan yang sangat efektif [13]. Jaringan EfficientNet memiliki arsitektur dari B0 hingga B7, Jaringan EfficientNet memiliki jumlah blok MBCConv yang berbeda. Saat beralih dari EfficientNetB0 ke EfficientNetB7, kedalaman, lebar, resolusi, dan ukuran model terus meningkat dan akurasi juga ditingkatkan [14]. EfficientNet adalah arsitektur dengan MBCConv (*mobile inverted bottleneck convolution*) sebagai blok dasar yang dapat di *scale up*.



Gambar 5. Arsitektur EfficientNet B0 [14].

2.6 Precision, recall, dan F-Measure

Precision, *recall*, dan *F-Measure* merupakan parameter yang digunakan dalam pengujian hasil klasifikasi. *Precision* adalah proporsi kasus Prediksi Positif yang benar-benar Positif Sedangkan *recall* adalah proporsi kasus *Real Positive* yang diprediksi dengan Positif dengan benar [18]. Secara umum, *precision* dan *recall* dapat dirumuskan sesuai dengan persamaan 4 dan detail pembahasan pada Gambar 6.

		Actual	
		Positive	Negative
Predicted	Positive	TN	FN
	Negative	FP	TP

Gambar 6. Confusion Matrix.

Gambar 6 adalah gambaran coefficient metrics, seperti yang dapat dilihat *coefficient metrics* terdiri dari *True positive* (TP) yang berarti data yang diklasifikasi oleh model memiliki output *true* dan label sesungguhnya dari data tersebut adalah *true*. *True Negative* (TN) adalah nilai yang diklasifikasikan sebagai false oleh model dan memiliki label yang sesungguhnya bernilai *false*.

False Positive (FP) adalah data yang diklasifikasikan positive oleh model tapi nilai sesungguhnya adalah false, False Negative adalah kebalikan dari false positive, dimana pada FN data di klasifikasikan sebagai negative namun nilai sesungguhnya adalah positive. Nilai coefficient metrics yang diperoleh dapat digunakan untuk mencari accuracy, precision, dan recall dengan persamaan 4:

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN}$$

$$Precision = \frac{TP}{TP+FP} \tag{4}$$

$$Recall = \frac{TP}{TP+FN}$$

Mengoptimalkan hasil yang didapatkan, diperlukan parameter pengukuran lainnya yaitu *F-measure*. *F-measure* secara efektif mereferensikan *True Positive* ke rata-rata dari Prediksi Positif dan *Real Positive*. *F-measure* dapat dirumuskan sesuai dengan persamaan 5. Semakin besar nilai *F-measure*, maka semakin baik pula hasil dari klasifikasi tersebut.

$$F_{measure} = 2x \frac{Precision \times Recall}{Precision + Recall} \tag{5}$$

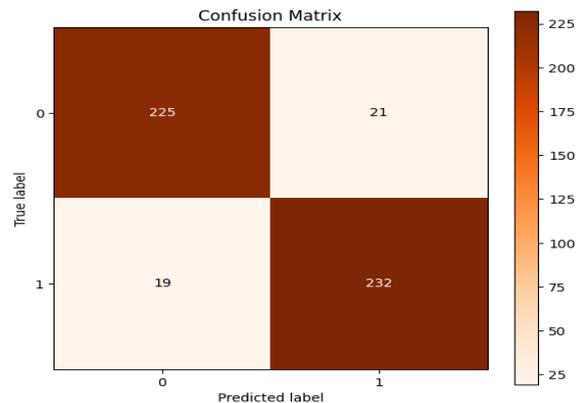
3 HASIL DAN PEMBAHASAN

Studi ini diimplementasikan pada *workstation* dengan CPU Core i7 (8th Gen) 2.20 GHz dengan RAM 8GB; Memori grafis 6GB dan diimplementasikan di library Tensorflow Python, dimana tensorflow yang digunakan adalah versi 2.9. hasil dari penelitian ini dapat di lihat pada Tabel 1. Hasil dari penelitian ini menunjukkan bahwa penggunaan model efficientNet B0 dapat mendeteksi penyakit Covid-19 dan akan mempunyai hasil yang lebih baik apabila menggunakan praproses CLAHE.

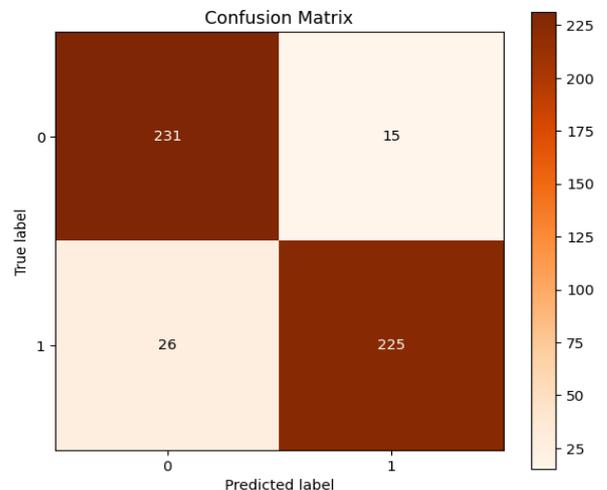
Tabel 1. Hasil EfficientNet B0

Model	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)
Dengan CLAHE	91.95	91.69	92.43	92.06
Tanpa CLAHE	91.75	93.75	89.64	91.64

Hasil dari penelitian menunjukkan bahwa klasifikasi dengan CLAHE memiliki performa yang lebih baik apabila dibandingkan tanpa praproses CLAHE. Seperti yang dapat dilihat pada tabel 1 akurasi dengan CLAHE lebih baik dengan nilai 91.95% sedangkan tanpa CLAHE hanya 91.75%. Pada *precision* model tanpa CLAHE memiliki hasil yang lebih baik yaitu 93.75%, sedangkan pada model dengan CLAHE memiliki performa 91,69%, namun pada nilai recall perbedaan tampak jelas dimana model dengan CLAHE memiliki hasil yang lebih baik yaitu 92.43 sedangkan tanpa CLAHE 89.65, sehingga performa keseluruhan model dapat nilai berdasarkan *F-measure* dimana model dengan CLAHE memiliki preforma lebih baik dengan 92.06 sedangkan tanpa CLAHE memiliki nilai 91.64%.

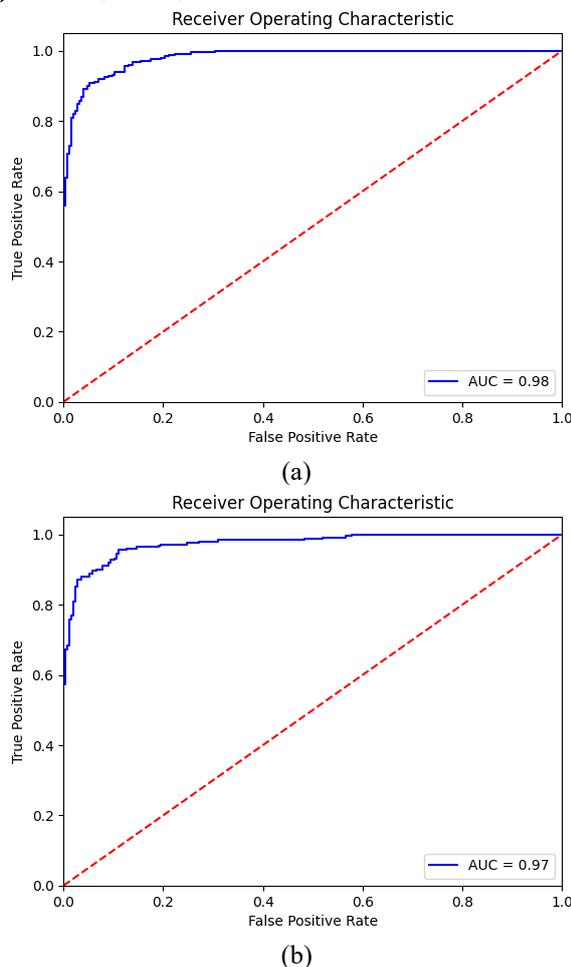


Gambar 7. Coefficient metrics EfficientNet B0 dengan CLAHE



Gambar 8. Coefficient metrics EfficientNet B0 tanpa CLAHE.

Performa Pada penelitian ini dilakukan dengan membandingkan hasil dari EfficientNet yang dilakukan dengan praproses CLAHE dan tanpa praproses CLAHE. Hasil uji coba menunjukkan dengan menggunakan CLAHE dapat memperoleh performa yang lebih baik. Hasil ini dapat di lihat pada Gambar 7 coefficient metrics dengan CLAHE diperoleh TP 232, FP 19, FN 21, TN 225, sedangkan hasil dari tanpa menggunakan CLAHE dapat dilihat pada Gambar 8, dimana TP 225, FP 26, FN 15, dan TN 231. Pada penelitian yang dilakukan nilai accuracy kurang baik digunakan sebagai evaluasi disebabkan jumlah data positif dan negatif Covid-19 yang berbeda, untuk melihat performa sebaiknya dilakukan dengan melihat *precision*, *recall*, dan *F-measure*.



Gambar 9. a. Hasil ROC-AUC model EfficientNet B0 dengan Clahe. b. Hasil ROC-AUC model EfficientNet B0 tanpa CLAHE.

Untuk melihat performa model deep learning yang dibuat dapat juga dilihat dari kurva Area Under the Curve (AUC) - Receiver Operating Characteristics (ROC). ROC-AUC adalah salah satu metrik evaluasi terpenting untuk memeriksa kinerja model klasifikasi. Kurva AUC - ROC adalah pengukuran kinerja untuk masalah klasifikasi pada berbagai pengaturan ambang batas. ROC adalah kurva probabilitas dan AUC mewakili tingkat atau ukuran keterpisahan. Ini memberi tahu seberapa banyak model mampu

membedakan antar kelas. Semakin tinggi AUC, semakin baik model dalam memprediksi kelas 0 sebagai 0 dan kelas 1 sebagai 1. Dengan analogi, semakin tinggi AUC, semakin baik model dalam membedakan antara pasien dengan penyakit dan tanpa penyakit [19]. Hasil ROC - AUC dari model yang dibuat menunjukkan model dengan CLAHE memiliki hasil yang lebih baik dengan nilai 0.98 dan model tanpa CLAHE memiliki nilai 0.97, untuk lebih jelas dapat dilihat pada gambar 9.

Performa EfficientNet B0 dengan CLAHE memiliki hasil yang lebih baik apabila dibandingkan dengan arsitektur deep learning lain seperti Resnet50 dan Alexnet [20]. Tabel 2 adalah perbandingan performa EfficientNet B0 dengan praproses CLAHE dibanding arsitektur lain dengan praproses CLAHE dalam klasifikasi Covid-19 dengan dataset yang sama.

Tabel 1. Performa Klasifikasi model dengan praproses CLAHE.

Model	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)
Efficient Net B0	91.95	91.69	92.43	92.06
Resnet 50 [20]	88.73	94.52	82.47	88.08
AlexNet [20]	83.70	85.71	81.27	83.44

4 KESIMPULAN

Hasil dari penelitian ini adalah VGG16 dengan preprocessing CLAHE memiliki hasil yang lebih baik dibandingkan dengan metode lainnya dengan akurasi 94,97%, presisi 97,88%, recall 92,03% dan F-measure 94,87%, kinerja terendah adalah Alexnet. Namun berdasarkan hasil recall, transfer learning Resnet50 dengan CLAHE memiliki hasil yang lebih baik dibandingkan dengan metode lain dengan perolehan 93,53%. Kurva ROC menunjukkan bahwa VGG dengan CLAHE memiliki ROC terbaik dengan 1,0 dan AlexNet tanpa CLAHE memiliki ROC terendah dengan 0,92. Model dengan preprocessing CLAHE memiliki performa yang lebih baik jika dibandingkan dengan model tanpa CLAHE, namun beberapa model tanpa CLAHE memiliki presisi yang lebih baik. Alasan VGG16 lebih baik dari model lainnya adalah karena dataset menggunakan gambar grayscale sehingga proses pembelajaran menggunakan VGG16 yang memiliki arsitektur lebih sederhana dibandingkan arsitektur lainnya menjadi lebih efisien..

5 DAFTAR PUSTAKA

- [1] covid19.go.id, "Situasi COVID-19 di Indonesia," 2023. <https://covid19.go.id/artikel/2023/06/02/situas-i-covid-19-di-indonesia-update-2-juni-2023> (accessed Jun. 03, 2023).
- [2] M. Jenkins, O. Johnson, T. Helliwell and C. P. Johnson, "Case Report: Suspected COVID-19 death in the community - histological lung

- findings and the challenges faced by the pathologist,” , *F1000Research*, vol. 9, 2020, doi: 10.12688/f1000research.23629.1.
- [3] A. Ghaffari, R. Meurant and A. Ardakani, “COVID-19 Serological Tests: How Well Do They Actually Perform?,” , *Diagnostics*, vol. 10, no. 7, Jul. 2020, doi: 10.3390/diagnostics10070453.
- [4] A. Scohy, A. Anantharajah, M. Bodéus, B. Kabamba-Mukadi, A. Verroken and H. Rodriguez-Villalobos, “Low performance of rapid antigen detection test as frontline testing for COVID-19 diagnosis,” , *Journal of Clinical Virology*, vol. 129, Aug. 2020, doi: 10.1016/j.jcv.2020.104455.
- [5] X. Yang, Z. Jinyu, Z. Yichen, Z. Shanghang and P. Xie, “COVID-CT-Dataset: A CT Image Dataset about COVID-19,” , 2020. Accessed: Jul. 09, 2020. [Online]. Available: <https://www.medrxiv.org/>
- [6] Q. Yang ... G. Wang, “Low-Dose CT Image Denoising Using a Generative Adversarial Network With Wasserstein Distance and Perceptual Loss,” , *IEEE Transactions on Medical Imaging*, vol. 37, no. 6, pp. 1348–1357, Jun. 2018, doi: 10.1109/TMI.2018.2827462.
- [7] V. Kumar Singh, M. Abdel-Nasser, N. Pandey and D. Puig, “LungINFseg: Segmenting COVID-19 Infected Regions in Lung CT Images Based on a Receptive-Field-Aware Deep Learning Framework,” , *Diagnostics*, vol. 11, no. 2, p. 158, 2021, doi: 10.3390/diagnostics11020158.
- [8] Y. Wang and Q. Zeng, “Ovarian Tumor Texture Classification Based on Sparse Auto-Encoder Network Combined with Multi-Feature Fusion and Random Forest in Ultrasound Image,” , *Journal of Medical Imaging and Health Informatics*, vol. 11, no. 2, pp. 424–431, Oct. 2020, doi: 10.1166/JMIHI.2021.3298.
- [9] Z. He ... W. K. Ming, “The Influence of Average Temperature and Relative Humidity on New Cases of COVID-19: Time-Series Analysis,” , *JMIR Public Health Surveill* 2021;7(1):e20495 <https://publichealth.jmir.org/2021/1/e20495>, vol. 7, no. 1, p. e20495, Jan. 2021, doi: 10.2196/20495.
- [10] E. A. A. Alaoui, S. C. K. Tekouabou, S. Hartini, Z. Rustam, H. Silkan and S. Agoujil, “Improvement in automated diagnosis of soft tissues tumors using machine learning,” , *Big Data Mining and Analytics*, vol. 4, no. 1, pp. 33–46, Mar. 2021, doi: 10.26599/BDMA.2020.9020023.
- [11] J. Shuja, E. Alanazi, W. Alasmary and A. Alashaikh, “Covid-19 Datasets: A Survey And Future Challenges,” , 2020, doi: 10.1101/2020.05.19.20107532.
- [12] I. D. Apostolopoulos and T. A. Mpesiana, “Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks,” , *Physical and Engineering Sciences in Medicine*, vol. 43, pp. 635–640, 2020, doi: 10.1007/s13246-020-00865-4.
- [13] M. Tan and Q. V Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” , in *Proceedings of the 36th International Conference on Machine Learning*, May 2019, pp. 6105–6114. Accessed: Jun. 08, 2021. [Online]. Available: <http://proceedings.mlr.press/v97/tan19a.html>
- [14] B. Baheti, S. Innani, S. Gajre and S. Talbar, “Eff-UNet: A novel architecture for semantic segmentation in unstructured environment,” , in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2020, vol. 2020-June, pp. 1473–1481. doi: 10.1109/CVPRW50498.2020.00187.
- [15] E. Soares, P. Angelov, S. Biaso, M. Higa Froes and D. K. Abe, “SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification,” , *medrxiv*, 2020, doi: 10.1101/2020.04.24.20078584.
- [16] R. E. Putra, H. Tjandrasa and N. Suciati, “Severity Classification of Non-Proliferative Diabetic Retinopathy Using Convolutional Support Vector Machine,” , *International Journal of Intelligent Engineering and Systems*, vol. 13, no. 4, 2020, doi: 10.22266/ijies2020.0831.14.
- [17] J. Shijie, W. Ping, J. Peiyi and H. Siping, “Research on data augmentation for image classification based on convolution neural networks,” , *Proceedings - 2017 Chinese Automation Congress, CAC 2017*, vol. 2017-January, pp. 4165–4170, Dec. 2017, doi: 10.1109/CAC.2017.8243510.
- [18] D. M. W. Powers, “Evaluation: From Precision, Recall And F-Measure to ROC, Informedness, Markedness & Correlation,” , *ArXiv*, vol. 2, no. 1, pp. 37–63, 2011, Accessed: May 14, 2019. [Online]. Available: <http://www.bioinfo.in/contents.php?id=51>
- [19] S. H. Park, J. M. Goo and C. H. Jo, “Receiver Operating Characteristic (ROC) Curve: Practical Review for Radiologists,” , *Korean Journal of Radiology*, vol. 5, no. 1, p. 11, 2004, doi: 10.3348/KJR.2004.5.1.11.
- [20] A. Irsyad and H. Tjandrasa, “Detection of COVID-19 from Chest CT Images Using Deep Transfer Learning,” , *International Conference On Information & Communication Technology And System (ICTS)*, 2021.