

TRANSFORMASI CITRA RETINA DENGAN CLAHE UNTUK MENINGKATKAN AKURASI RESNET DALAM KLASIFIKASI PENYAKIT RETINA

Galih Restu Baihaqi*¹, Shafatyra Reditha Shalsadilla², Afifulail Maya Nur Maulidiya³

¹Fakultas Ilmu Komputer / Universitas Brawijaya, ³Fakultas Kedokteran / Universitas Brawijaya
Malang, Indonesia

Email: ¹galihrestubaihq@student.ub.ac.id, ²shafatyrare@student.ub.ac.id,
³amnmaulidiya04@student.ub.ac.id

Abstract

Retinal diseases are among the serious conditions that can lead to vision impairment and, in severe cases, blindness. Data indicate that 6.3 to 17.9 percent of cases per 100,000 people globally suffer from retinal diseases each year. Early diagnosis of retinal diseases is crucial; however, the diagnosis process often requires significant time. A promising approach for faster early diagnosis of retinal diseases is by utilizing Artificial Intelligence models, such as ResNet, a CNN architecture known for its effective image classification capabilities. The dataset used for this study is the Retinal OCT Images dataset from Kaggle, consisting of 83,600 images across four classes. OCT images typically have low contrast, necessitating image transformation techniques like CLAHE. CLAHE has been proven to improve the ResNet model's accuracy by 2%. Initially, ResNet without CLAHE achieved an accuracy, recall, and F1-Score of 92% and a precision of 93%. With image transformation through CLAHE in the preprocessing stage, ResNet achieved an accuracy, precision, recall, and F1-Score of 94% each. Both approaches reached optimal accuracy at epoch 27, though the training graph for ResNet without CLAHE was more fluctuative. With higher accuracy, the ResNet50 + CLAHE model was determined to be the best-performing model in this study.

Keywords: CLAHE, Classification, ResNet, Retinal

Abstraksi

Penyakit pada retina merupakan salah satu penyakit serius yang dapat menyebabkan gangguan penglihatan, bahkan dapat menyebabkan kebutaan. Data menyebutkan sebanyak 6,3 – 17,9 persen kasus setiap 100.000 penduduk di dunia menderita penyakit retina setiap tahunnya. Melakukan diagnosis dini penyakit retina sangat penting, namun biasanya memerlukan waktu yang lama dalam proses diagnosis. Salah satu pendekatan yang dapat digunakan untuk mendiagnosis dini penyakit retina dengan lebih cepat yaitu dengan memanfaatkan model – model Artificial Intelligence seperti ResNet yang merupakan bagian dari arsitektur CNN yang dapat dengan baik melakukan proses klasifikasi pada data-data gambar. Dataset yang digunakan diperoleh dari Kaggle dengan nama Retinal OCT Images (optical coherence tomography) yang terdiri dari 4 kelas dengan total data sebanyak 83.600 data gambar. Data OCT umumnya memiliki kontras yang rendah sehingga perlu teknik transformasi citra menggunakan CLAHE. CLAHE terbukti dapat meningkatkan akurasi model ResNet

sebanyak 2%. Awalnya ResNet tanpa CLAHE memperoleh akurasi, recall, dan F1-Score masing-masing sebesar 92% dengan presisi yang diperoleh sebesar 93%. Dengan proses transformasi citra pada tahapan preprocessing menggunakan CLAHE, ResNet memperoleh akurasi, presisi, recall dan F1-Score masing-masing sebesar 94%. Keduanya memperoleh perolehan epoch terbaik berdasarkan akurasi di angka 27, namun grafik pelatihan yang dihasilkan model ResNet tanpa CLAHE lebih berfluktuatif. Dengan perolehan akurasi yang lebih tinggi, model ResNet50 + CLAHE merupakan model yang terbaik selama pengujian.

Kata Kunci: CLAHE, Klasifikasi, ResNet, Retina

1. PENDAHULUAN

Retina merupakan lapisan bagian belakang mata yang sensitif terhadap cahaya yang berfungsi sebagai bagian dari mata yang menerima rangsangan cahaya dan meneruskannya ke otak untuk diolah menjadi gambar. Data menyebutkan bahwa ada 6,3 – 17,9 persen kasus setiap 100.000 penduduk di dunia setiap tahun yang menderita penyakit retina. Di Indonesia telah dilakukan sebanyak 349 operasi penempelan retina di RSUPN dr. Cipto Mangunkusumo sejak 2008 – 2009 [1]. Kesehatan retina sangat penting dalam menentukan atau menjaga kualitas penglihatan pada manusia, dan gangguan – gangguan pada retina dapat menyebabkan kebutaan apabila tidak segera didiagnosis dan ditangani dengan cepat. Oleh karena itu, deteksi dini penyakit retina sangat penting dalam oftamologi untuk menghindari risiko kebutaan, sementara proses pada umumnya membutuhkan waktu yang lama dan biaya yang mahal.

Baru – baru ini, perkembangan teknologi khususnya *Artificial Intelligence* (AI) sangat pesat, khususnya *Convolutional Neural Network* (CNN) yang merupakan bagian dari *Deep Learning* [2]. CNN telah memberikan kontribusi yang sangat besar dalam menganalisis citra – citra medis [3]. *Residual Network* (ResNet) merupakan salah satu arsitektur dari CNN yang populer dalam menganalisis citra – citra medis [4]. Cara kerja ResNet yaitu berfokus pada pembelajaran dengan residual yang memungkinkan ResNet memahami perbedaan yang dimiliki oleh *input* dan *output*. Setiap *block residual* yang dimiliki ResNet memiliki jalur yang memungkinkan untuk mengalirkan informasi ke lapisan berikutnya. Hal ini dapat membantu mengatasi terjadinya penurunan akurasi pada jaringan yang lebih dalam [5]. Dibandingkan dengan model CNN lainnya, ResNet lebih efisien dalam penggunaan parameter dan lebih robust dalam mengatasi kompleksitas kontras dan fitur citra medis yang beragam. Selain itu ResNet memiliki kemampuan untuk mengatasi *vanishing gradient* pada jaringan yang dalam [6]. Pada sebuah penelitian [7], penggunaan ResNet untuk mengklasifikasikan kualitas citra penyakit retina dengan data yang digunakan merupakan data citra fundus retina memperoleh akurasi terbaiknya sebesar 86,2%.

Namun, masalah yang biasanya dihadapi dalam klasifikasi citra retina adalah banyaknya variasi kontras pada gambar yang diperoleh dari perangkat – perangkat kedokteran, misalnya pada alat *Optical Coherence Tomography* (OCT) [8]. Banyaknya

variasi kontras yang dihasilkan dari OCT dapat disebabkan oleh perbedaan kondisi cahaya saat pengambilan gambar. Selain itu tingkat kejelasan lensa dan kualitas dari alat OCT itu sendiri dapat mempengaruhi kualitas dan keberagaman gambar yang dihasilkan. Hal ini dapat menyebabkan *Deep Learning* kesulitan dalam mengenali fitur-fitur penting pada retina [9]. Oleh karena itu, perlu adanya peningkatan kualitas citra yang dapat meningkatkan kontras pada Citra sehingga fitur yang dihasilkan lebih relevan dan mudah diekstraksi oleh model ResNet.

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan salah satu teknik pengolahan citra yang efektif dalam meningkatkan kontras lokal pada citra medis. CLAHE bekerja dengan cara membatasi peningkatan kontras untuk menghindari terjadinya amplifikasi noise [10]. CLAHE membagi citra menjadi bagian – bagian dan melakukan *histogram equalization* pada setiap bagian dengan pembatasan kontras yang sudah disesuaikan, sehingga CLAHE dapat meningkatkan kontras pada citra dengan lebih merata dan detail yang sangat bermanfaat untuk menciptakan fitur yang berkualitas pada citra retina [11]. Pada sebuah penelitian [12], CLAHE berfungsi sangat baik dalam meningkatkan kontras pada citra retina dan dapat meningkatkan akurasi pada CNN hingga mencapai 90%.

Secara keseluruhan, pada penelitian ini akan menerapkan teknik CLAHE untuk meningkatkan kontras pada citra retina dan melakukan klasifikasi penyakit menggunakan ResNet. CLAHE diharapkan dapat meningkatkan akurasi pada model ResNet untuk klasifikasi penyakit retina dan pada akhirnya dapat membantu dalam mendiagnosis dini penyakit retina dengan perolehan keputusan yang lebih cepat untuk membantu mengatasi kesehatan mata yang lebih baik.


2. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Penelitian terdahulu menunjukkan bahwa citra retina sangat penting untuk diagnosis penyakit mata. Dengan keterbatasan jumlah dokter spesialis mata, kamera fundus digital dan teknik *deep learning*, dapat membantu otomatisasi analisis citra. Dengan menggunakan model CNN, akurasi yang diperoleh sebesar 80,93% pada resolusi 31×35 piksel, yang menunjukkan potensi pendekatan ini dalam klasifikasi penyakit retina [13]. Penelitian lainnya dalam penggunaan *machine learning* dalam mengklasifikasikan penderita penyakit retina menunjukkan bahwa akurasi yang diperoleh sebesar 89,47% dengan model yang digunakan adalah RBM (*Restricted Boltzmann Machines*) [14]. Kedua studi yang disebutkan belum menggunakan teknik peningkatan kualitas kontras seperti CLAHE, yang dapat membantu meningkatkan kualitas fitur pada citra retina. Oleh karena itu, penelitian ini menggunakan teknik CLAHE untuk meningkatkan kontras dan model ResNet dalam upaya meningkatkan akurasi klasifikasi penyakit retina.

2.2. Penyakit Retina

Retina merupakan salah satu lapisan mata yang berfungsi penting dalam proses penglihatan. Kegunaan retina adalah sebagai penangkap cahaya dari mata yang kemudian dirubah menjadi sebuah sinyal yang dikirimkan ke otak untuk diolah dan diterjemahkan menjadi gambar atau visual. Retina sangat rentan dari berbagai penyakit dan dapat berakibat pada kualitas penglihatan yang pada akhirnya dapat menyebabkan kebutaan. Beberapa penyakit retina seperti *Choroidal Neovascularization* (CNV), *Diabetic Macular Edema* (DME), dan Drusen yang dapat disebabkan oleh faktor usia, penyakit lainnya seperti diabetes, dan faktor genetik. Penyakit – penyakit ini dapat mengakibatkan pandangan menjadi kabur [15]. Untuk menangkap gambar retina, digunakan alat medis yaitu *Optical Coherence Tomography* (OCT) dan penjelasan masing – masing penyakit ditunjukkan pada Gambar 1.




Gambar 1. Penyakit Retina Yang Diambil Menggunakan OCT

Gambar 1 merupakan contoh citra yang dihasilkan oleh OCT dan masing – masing label dengan nama *Choroidal Neovascularization* (CNV) yaitu penyakit pada retina yang disebabkan oleh pertumbuhan pembuluh darah yang tidak normal dari lapisan koroid menuju retina. Pembuluh darah ini rawan pecah yang mengganggu penglihatan akibat cairannya. *Diabetic Macular Edema* (DME) merupakan penyakit yang disebabkan oleh penumpukan cairan pada makula yang disebabkan oleh kebocoran pembuluh darah retina. Drusen adalah salah satu penyakit yang disebabkan oleh adanya endapan kecil protein dan lipid yang terbentuk dibawah retina yaitu pada lapisan bruch.

2.3. ResNet

Residual Network (ResNet) adalah salah satu arsitektur CNN yang dirancang untuk mengatasi masalah penurunan akurasi pada jaringan yang semakin dalam. Berbeda dengan CNN biasa yang menghubungkan lapisan secara sekuensial, ResNet menggunakan pendekatan *residual learning* dengan menambahkan jalur pintas. Setiap lapisan pada ResNet tidak hanya memproses data dari lapisan sebelumnya, tetapi juga menerima hasil dari lapisan-lapisan sebelumnya melalui jalur pintas yang dimiliki oleh ResNet. ResNet dapat mempertahankan aliran informasi dan gradien secara optimal dalam jaringan yang mendalam, sehingga mencegah terjadinya hilangnya gradien yang sering terjadi pada model *Deep Learning*. Gambar Blok ResNet ditunjukkan pada Gambar 2.



Gambar 2. ResNet

2.4. CLAHE

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan salah satu metode peningkatan kontras yang menerapkan teknik domain spasial untuk pemerataan peningkatan kontras pada citra sambil mempertimbangkan entropi maksimum dan melakukan pembatasan kontras yang efektif. Teknik ini cocok untuk meningkatkan kontras pada gambar medis yang relatif rendah [16]. Formula yang digunakan untuk menghitung tingkat abu – abu dari CLAHE ditunjukkan pada persamaan 1.

$$g = [g_{max} - g_{min}] \cdot P(f) + g_{min} \quad (1)$$

Dimana:

g = Nilai Pixel

g_{max} = Nilai Pixel Maksimum

g_{min} = Nilai Pixel Minimum

$P(f)$ = CPD = *Cumulative probability distribution*

Teknik distribusi nilai keabu-abuannya dapat diukur menggunakan persamaan 2.

$$g = g_{min} - \left(\frac{1}{a}\right) \cdot \ln [1 - P(f)] \quad (2)$$

$$y = P(f(x \setminus b)) = \int_0^x \frac{x}{b^2} e^{\left(\frac{-x^2}{2b^2}\right)} \quad (3)$$

Dimana:


a = Parameter Klip

y = Nilai Probabilitas Komulatif / Rayleigh

b = *Scale Parameter* untuk Rayleigh

2.5. Confussion Matrix

Confussion Matrix merupakan salah satu teknik yang biasanya digunakan untuk mengevaluasi hasil klasifikasi yang dihasilkan oleh AI, baik itu model *Machine Learning* maupun *Deep Learning*. *Confussion Matrix* berguna untuk menunjukkan seberapa akurat model yang sudah dilatih pada data *training* untuk kemudian dievaluasi menggunakan data *testing* yang sudah disiapkan [17]. *Confussion Matrix* terdiri dari TP, TN, FP, dan FN dan ditunjukkan pada Gambar 3. TP adalah *True Positif*, TN adalah *True Negatif*, FP adalah *False Positif*, dan FN *False Negatif*.



Gambar 3. Confussion Matrix


3. METODE PENELITIAN

3.1. Jenis Penelitian


Jenis penelitian yang dilakukan adalah penelitian eksperimental, yang bertujuan untuk mengevaluasi efektivitas teknik peningkatan kontras menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE) pada model ResNet dalam klasifikasi penyakit retina.

3.2. Dataset

Dataset yang digunakan merupakan dataset yang diperoleh dari Kaggle dengan nama *Retinal OCT Images* (optical coherence tomography) yang terdiri dari 4 kelas yaitu CNV, DME, Drusen dan Normal. Total dataset yang diperoleh yaitu sebanyak 83.600 data yang diambil menggunakan alat OCT. Dataset yang digunakan tidak seimbang (*Imbalance*) dengan kelas mayoritas yaitu CNV sebanyak 44,5% (37.216 data). Sementara kelas lainnya seperti Normal, DME, dan Drusen masing-masing sebanyak 31,5% (26.344 data), 13,7% (11.420 data), dan 10,3% (8.620 data). Sebaran data pada dataset ditunjukkan pada Gambar 4 dan untuk masing-masing data gambar setiap kelasnya ditunjukkan pada Gambar 5.




Gambar 4. Sebaran Dataset Per Kelas



Gambar 5. Contoh Dataset Per Kelas

3.3. Preprocessing Data


Preprocessing data merupakan salah satu teknik yang digunakan untuk mempersiapkan data sebelum diproses oleh model. Pertama, teknik *preprocessing* yang diterapkan adalah penggunaan teknik CLAHE untuk meningkatkan kontras dari dataset, kemudian dataset *resize* menjadi ukuran 224x224. Ukuran ini adalah standar yang biasanya digunakan untuk proses – proses CNN dengan layer ResNet [18]. Selanjutnya dataset yang sudah melalui proses CLAHE dan *resize*, kemudian dataset dibagi menjadi 3 bagian yaitu data *train* yang berguna sebagai data pelatihan, *validasi* yang berguna untuk mengawasi proses pelatihan dan data *test* yang berguna untuk mengevaluasi model setelah selesai proses pelatihan. Alur untuk *preprocessing* data ditunjukkan pada Gambar 6.



Gambar 6. Blok Diagram Preprocessing Data

3.4. Blok Diagram Sistem

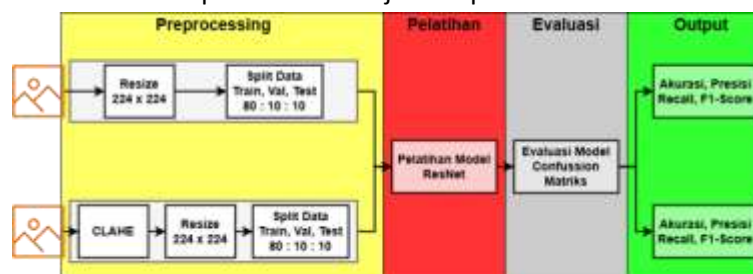
Sistem klasifikasi dibangun menggunakan model ResNet50. Alur kerja sistem dimulai dari *input* data gambar yang kemudian dilakukan proses *preprocessing* data. Kemudian setelah proses *preprocessing* data selesai, kemudian proses pelatihan terhadap data *train* dan *valid* yang bertugas untuk mengawasi pelatihan. Selanjutnya setelah model berhasil dilatih, model dievaluasi menggunakan *confusion matrix*. Proses ini ditunjukkan pada Gambar 7.



Gambar 7. Blok Diagram Sistem

3.5. Skenario Pengujian

Untuk menguji pengaruh CLAHE pada hasil peningkatan akurasi model ResNet dalam melakukan klasifikasi terhadap citra retina, dilakukan pengujian dengan membandingkan proses model ResNet tanpa melakukan transformasi CLAHE pada citra dengan model ResNet yang diproses pada data citra yang sudah ditransformasi menggunakan CLAHE. Kedua proses ini ditunjukkan pada Gambar 8.



Gambar 8. Blok Diagram Skenario Pengujian

Pada Gambar 8, proses dibedakan menjadi 4 bagian. Perbedaan keduanya ada pada proses *preprocessing* yang mana suatu dataset melewati teknik transformasi CLAHE dan tidak. Setelah tahapan preprocessing dilakukan, kemudian akan melalui proses pelatihan yang sama, yaitu proses pelatihan dengan model ResNet50 dengan 30 Epoch, *Learning Rate* 0,001, dan ukuran *Batch Size* yaitu 64. Setelah masing-masing proses pelatihan selesai, kemudian proses evaluasi untuk mengukur performa model yang sudah di latih menggunakan data *testing*. Kemudian, *output* yang dihasilkan untuk kedua model adalah nilai Akurasi, Presisi, Recall dan F1-Score.

3.6. Evaluasi Model

Nilai dari *confusion matrix* dapat digunakan untuk menghitung dan mengevaluasi model klasifikasi yang dibangun. Evaluasi model diukur berdasarkan akurasi, presisi, recall dan F1-score. Persamaan yang digunakan untuk menghitung akurasi, presisi, recall dan F1-Score masing-masing ditunjukkan oleh persamaan 4-7.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$Presisi = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$


$$F1 = 2 \cdot \frac{Presisi \cdot Recall}{Presisi + Recall} \quad (7)$$

Persamaan 4-7 merupakan indikator parameter yang digunakan untuk mengukur performa model. Akurasi merupakan nilai evaluasi untuk mengukur persentase prediksi yang benar dari total prediksi yang dihasilkan model. Presisi mengukur ketepatan model dalam memprediksi kelas positif. Recall mengukur seberapa benar model dalam mendeteksi kelas positif yang sebenarnya. F1-Score merupakan nilai rata – rata dari presisi dan recall.

4. HASIL DAN PEMBAHASAN

4.1. Proses CLAHE

CLAHE meningkatkan kontras lokal pada citra yang sangat cocok pada citra-citra yang memiliki kontras rendah. Hasil dari transformasi gambar sebelum dan sesudah CLAHE untuk masing-masing kelas ditunjukkan pada Gambar 9.



Gambar 9. Dataset Setelah Proses CLAHE

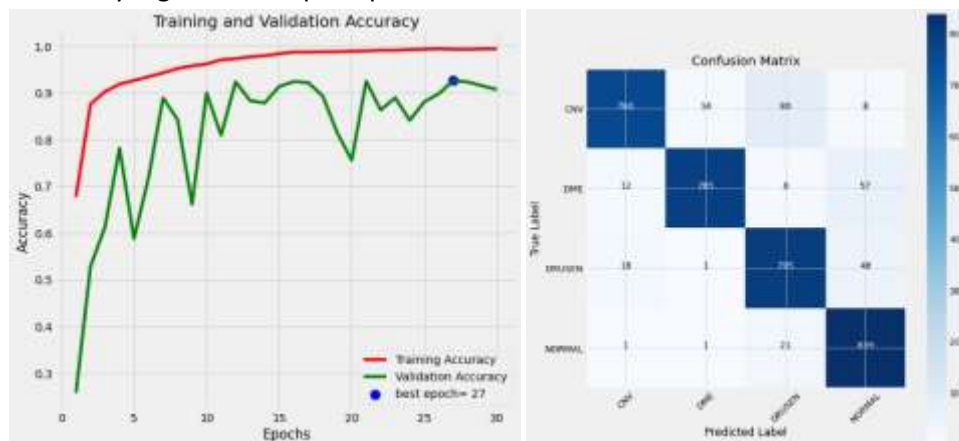
4.2. Down Sampling

Pada Gambar 4, dataset mengalami ketimpangan (*Imbalance*) sehingga perlu melakukan *down sampling* agar jumlah data pada setiap kelas sama. Hal ini dapat mengurangi tingkat *overfit* model pada data-data Mayoritas. Kelas minoritas adalah Drusen dengan jumlah 8.620 data sehingga kelas lainnya CNV, Normal, dan DME hanya digunakan sebanyak 8.620 data, sehingga data yang diproses untuk model ini sebanyak 34.480 data. Dataset setelah dilakukan *Down Sampling* dengan sebaran masing – masing kelas sebanyak 25% (8.620 data) dilakukan pembagian data menjadi *train*, *val*, dan *test* dengan perbandingan 80:10:10 sehingga total data yang diproses untuk *train* sebanyak 27.584 data. Lalu untuk data *val* dan *test* masing-masing sebanyak 3.448 data.

4.3. Hasil Evaluasi Model

4.3.1. Model ResNet Tanpa CLAHE

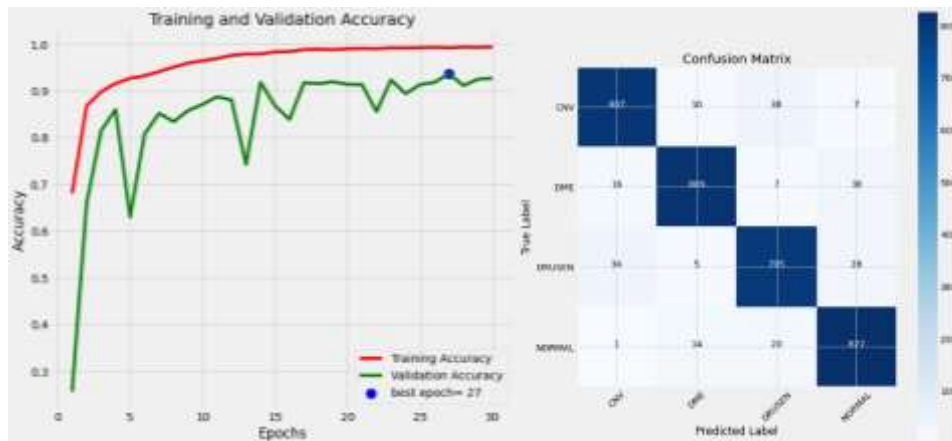
Gambar – gambar tanpa CLAHE merupakan gambar dengan kontras rendah seperti pada Gambar 9. Selama proses pelatihan, *epoch* terbaiknya berdasarkan akurasi pelatihannya ditunjukkan pada *epoch* ke 27 yang ditunjukkan pada Gambar 10 (a). Pada Gambar 10 (b) merupakan hasil *Confussion matrix* yang menunjukkan bawah model berhasil memprediksi terbaik pada kelas Normal dengan benar sebanyak 839. Sementara prediksi model terburuk pada kelas CNV dengan prediksi benar sebanyak 760. Akurasi yang dihasilkan pada proses model ini adalah 92%.



Gambar 10. (a) Proses Training, (b) Hasil Confussion Matrix Model ResNet Tanpa CLAHE

4.3.2. Model ResNet Dengan CLAHE

Gambar – gambar CLAHE merupakan gambar dengan kontras yang sudah di transformasi seperti pada Gambar 9. Selama proses pelatihan, *epoch* terbaiknya berdasarkan akurasi pelatihannya ditunjukkan pada *epoch* ke 27 juga, seperti ditunjukkan pada Gambar 11 (a). Pada Gambar 11 (b) merupakan hasil *Confussion matrix* yang menunjukkan bawah model ResNet dengan CLAHE berhasil memprediksi terbaik pada kelas Normal dengan benar sebanyak 827. Sementara prediksi model terburuk pada kelas Drusen dengan prediksi benar sebanyak 795. Akurasi yang dihasilkan pada proses model ini adalah 94%.



Gambar 11. (a) Proses Training, (b) Hasil Confussion Matrix Model ResNet + CLAHE

4.4. Evaluasi Keseluruhan

Perolehan *epoch* terbaik berdasarkan akurasi untuk kedua model yaitu model ResNet tanpa CLAHE dan model ResNet dengan CLAHE menunjukkan bahwa keduanya memiliki perolehan *epoch* terbaik di angka 27, walaupun grafik dari perolehan proses *training* model ResNet tanpa CLAHE lebih berfluktuatif. Namun untuk mengevaluasinya, model terbaik diukur berdasarkan perolehan akurasi, presisi, recall dan F1-Score yang tertinggi dan hasil menunjukkan bahwa model ResNet dengan CLAHE menunjukkan nilai yang lebih tinggi. Secara keseluruhan, model ResNet baik dengan CLAHE maupun tanpa CLAHE dapat mengungguli akurasi yang dihasilkan oleh CNN Base. Hasil rekap dari perbandingan ketiganya ditunjukkan pada Tabel 1.

Tabel 1. Perbandingan Hasil Evaluasi Model

Nama Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
CNN Base	77	77	77	77
ResNet50	92	93	92	92
ResNet50 + CLAHE	94	94	94	94

5. KESIMPULAN

Penyakit retina merupakan kondisi serius yang dapat menyebabkan gangguan penglihatan hingga kebutaan, sehingga diagnosis dini sangat penting. Pada penelitian ini, model ResNet diterapkan untuk klasifikasi penyakit retina dengan teknik peningkatan kontras citra menggunakan CLAHE. Hasil menunjukkan bahwa model ResNet tanpa penerapan CLAHE menghasilkan akurasi 92%, presisi 93%, recall 92%, dan F1-Score 92% pada epoch terbaik di epoch ke-27. Sementara itu, dengan penerapan CLAHE, performa meningkat menjadi akurasi, presisi, recall, dan F1-Score sebesar 94%, dengan epoch terbaik yang sama, namun menunjukkan grafik kinerja yang lebih stabil. ResNet juga dapat secara signifikan mengungguli model CNN base. Penerapan CLAHE secara signifikan juga membantu model ResNet dalam menghasilkan hasil klasifikasi yang lebih akurat dan stabil, mengurangi fluktuasi performa model dan risiko bias dalam

pengenalan fitur penting pada citra medis retina. Temuan ini mendukung bahwa teknik pengolahan citra seperti CLAHE efektif dalam membantu model deep learning menangkap informasi yang lebih relevan pada citra medis yang kontrasnya rendah, seperti dari alat OCT. Kedepannya, penelitian ini dapat dikembangkan dengan cara membandingkan hasil dengan model-model *deep learning* lainnya.

DAFTAR PUSTAKA

- [1] L. N. Islami, N. K. Fatmawati, and E. Sawitri, "Profil Penderita Ablasio Retina Eksudatif di Klinik Mata SMEC Tahun 2019 - 2022," *Jurnal Kesehatan Andalas*, vol. 12, no. 3, pp. 128–133, 2023, [Online]. Available: <http://jurnal.fk.unand.ac.id>
- [2] J. Steven Iskandar and R. P. Kristianto, "Pengenalan dan Klasifikasi Ragam Kue Indonesia menggunakan Arsitektur ResNet50V2 pada Convolutional Neural Network (CNN)," in *SEMINAR NASIONAL AMIKOM SURAKARTA (SEMNAS)*, 2023, pp. 81–92.
- [3] G. R. Baihaqi, B. D. Setiawan, and L. Muflikhah, "Implementasi Convolution Neural Network untuk Klasifikasi Kanker Usus Besar dengan Normalisasi GhostWeight," in *Seminar Nasional Teknologi dan Rekayasa Informasi (SENTRIN)*, 2024.
- [4] C. Wang, "Federated Learning with ResNet-18 for Medical Image Diagnosis," *Proceedings of the 2023 8th International Conference on Multimedia Systems and Signal Processing*, 2023, doi: 10.1145/3613917.3613922.
- [5] C. Huang, "On an Interpretation of ResNets via Gate-Network Control," *Neural Comput*, vol. 35, pp. 1566–1592, 2023, doi: 10.1162/neco_a_01600.
- [6] S. A. Hasanah, A. A. Pravitasari, A. S. Abdullah, I. N. Yulita, and M. H. Asnawi, "A Deep Learning Review of ResNet Architecture for Lung Disease Identification in CXR Image," *Applied Sciences*, vol. 13, no. 24, 2023, doi: 10.3390/app132413111.
- [7] M. Bolla, S. Biswas, and R. Palanisamy, "Deep Learning Based Quality Prediction of Retinal Fundus Images," *Current Directions in Biomedical Engineering*, vol. 9, pp. 706–709, 2023, doi: 10.1515/cdbme-2023-1177.
- [8] S. A. P., S. Kar, G. S. V. Gopi, and P. Palanisamy, "OctNET: A Lightweight CNN for Retinal Disease Classification from Optical Coherence Tomography Images," *Comput Methods Programs Biomed*, p. 105877, 2020, doi: 10.1016/j.cmpb.2020.105877.
- [9] L. Chen, C. Tang, Z. H. Huang, M. Xu, and Z. Lei, "Contrast enhancement and speckle suppression in OCT images based on a selective weighted variational enhancement model and an SP-FOOPDE algorithm," *Journal of the Optical Society of America A*, vol. 38, no. 7, pp. 973–984, Jul. 2021, doi: 10.1364/JOSAA.422047.
- [10] A. B and K. Kalirajan, "Contrast Enhancement of Alzheimer's MRI using Histogram Analysis," *Journal of Innovative Image Processing*, 2023, doi: 10.36548/jiip.2023.4.003.

- [11] A. Sarif and D. Gunawan, "Perbandingan Metode Penyesuaian Kontras Citra Pada Pengenalan Ekspresi Wajah Menggunakan Fine-Tuning AlexNet," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 3, p. 1144, Jul. 2023, doi: 10.30865/mib.v7i3.6382.
- [12] D. A. Anam, L. Novamizanti, and S. Rizal, "Classification of Retinal Pathology via OCT Images using Convolutional Neural Network," in *2021 International Conference on Computer System, Information Technology, and Electrical Engineering (COSITE)*, 2021, pp. 12–17. doi: 10.1109/COSITE52651.2021.9649630.
- [13] B. K. Triwijoyo, B. S. Sabarguna, W. Budiharto, and E. Abdurachman, "2 - Deep learning approach for classification of eye diseases based on color fundus images," in *Diabetes and Fundus OCT*, A. S. El-Baz and J. S. Suri, Eds., in *Computer-Assisted Diagnosis*, Elsevier, 2020, pp. 25–57. doi: <https://doi.org/10.1016/B978-0-12-817440-1.00002-4>.
- [14] M. Bader Alazzam, F. Alassery, and A. Almulihi, "Identification of Diabetic Retinopathy through Machine Learning," *Mobile Information Systems*, vol. 2021, no. 1, p. 1155116, 2021, doi: <https://doi.org/10.1155/2021/1155116>.
- [15] R. Denandra, A. Fariza, and Y. R. Prayogi, "Eye Disease Classification Based on Fundus Images Using Convolutional Neural Network," in *2023 International Electronics Symposium (IES)*, 2023, pp. 563–568. doi: 10.1109/IES59143.2023.10242558.
- [16] B. B. Singh and S. Patel, "Efficient Medical Image Enhancement using CLAHE Enhancement and Wavelet Fusion," 2017.
- [17] I. Markoulidakis, I. Rallis, I. Georgoulas, G. Kopsiaftis, A. Doulamis, and N. Doulamis, "Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem," *Technologies (Basel)*, vol. 9, no. 4, 2021, doi: 10.3390/technologies9040081.
- [18] M. Bunea and G. M. Danciu, "Pneumonia Image Classification Using DenseNet Architecture," *Information*, vol. 15, no. 10, 2024, doi: 10.3390/info15100611.