

Pengaruh Contrast Limited Adaptive Histogram Equalization Dalam Klasifikasi CT-Scan Tumor Ginjal Menggunakan Deep Learning

Nanda Jannata¹, Febi Yanto², Lestari Handayani³, Eka Pandu Cynthia Kurnia⁴

^{1,2,3,4} Program Studi Teknik Informatika

Universitas Islam Negeri Sultan Syarif Kasim, Pekanbaru, Riau, Indonesia

E-mail: 11950111721@students.uin-suska.ac.id¹, febiyanto@uin-suska.ac.id^{*2},

Lestari.handayani@uin-suska.ac.id³, eka.pandu.cynthia@uin-suska.ac.id⁴

Abstract – The human excretory system, comprising the kidneys, ureters, and bladder, plays a crucial role in maintaining overall body health by filtering blood and eliminating waste products, including water and toxins. However, kidneys are susceptible to various diseases, such as kidney tumors, which present a significant global health challenge, with over 430,000 new cases reported in 2020. This research focuses on using CT-scan imaging techniques to analyze and assess kidney tumors. The study employs the Image Enhancement Contrast Limited Adaptive Histogram Equalization (CLAHE) method to enhance the quality of Kidney Tumor CT-Scan images for deep learning classification using the MobileNetV2 Architecture. The dataset, consisting of 4,560 images, is divided into training, validation, and testing sets in an 80:20 ratio. Applying CLAHE with a clip limit of 20 and an 8x8 tile grid significantly improves evaluation metrics compared to non-CLAHE datasets, achieving an impressive f1-score of 99.56% and accuracy of 99.56%. This improvement is achieved using the Adam optimizer with a learning rate of 0.01. These findings underscore the efficacy of CLAHE in enhancing the model's performance in kidney tumor classification. They are particularly valuable for radiologists as they enhance diagnostic accuracy and efficiency, potentially reducing diagnostic errors and improving patient outcomes.

Keywords – CLAHE, Classification, CT-Scan, MobileNetV2, Tumor, Kidney.

Intisari - Sistem ekskresi manusia, yang terdiri dari ginjal, ureter, dan kandung kemih, memainkan peran penting dalam menjaga kesehatan tubuh. Ginjal, organ vital dalam sistem ekskresi, bertanggung jawab untuk menyaring darah dan membuang limbah, termasuk air dan racun, dari tubuh. Namun, ginjal dapat terserang berbagai penyakit, salah satunya adalah tumor ginjal. Tumor ginjal menjadi masalah kesehatan global yang signifikan, dengan lebih dari 430.000 kasus baru dilaporkan pada tahun 2020. Penelitian ini menggunakan metode pencitraan CT-scan untuk analisis dan penilaian tumor ginjal. Teknik *Image Enhancement Contrast Limited Adaptive Histogram Equalization* (CLAHE) diterapkan untuk meningkatkan kualitas citra CT-Scan Tumor Ginjal dalam klasifikasi *deep learning* menggunakan Arsitektur *MobileNetV2*. Dataset CT-Scan Tumor Ginjal yang terdiri dari 4.560 gambar dibagi menjadi data pelatihan, validasi, dan pengujian dengan rasio 80:20. Penggunaan *CLAHE* dengan clip limit 20 dan tile grid 8x8 menghasilkan hasil evaluasi yang lebih tinggi dibandingkan dataset *non-clahe*, yaitu f1-score 99,56% dan accuracy 99,56%. Hal ini dicapai dengan optimizer Adam dan learning rate 0,01. Temuan ini menunjukkan bahwa penerapan teknik CLAHE dapat meningkatkan kinerja model dalam mengklasifikasikan tumor ginjal. Hasil ini sangat penting bagi ahli radiologi karena memungkinkan mereka untuk mendiagnosa tumor ginjal dengan lebih akurat dan efisien, meningkatkan hasil diagnosa pasien dan mengurangi risiko kesalahan.

Kata Kunci - CLAHE, Klasifikasi, CT-Scan, MobileNetV2, Tumor, Ginjal.

I. PENDAHULUAN

Ginjal berfungsi menyaring darah, menjaga keseimbangan air dan garam, membuang limbah, mengatur tekanan darah, membantu produksi sel darah merah, dan mendukung kesehatan tulang. Ginjal yang rusak dapat menyebabkan berbagai penyakit dan berdampak pada organ lain[1]. Penyakit ginjal telah menjadi masalah utama masyarakat diseluruh dunia[2]. Menurut *World Cancer Reaserch Fund Internasional*, Ada lebih dari 430.000 kasus baru kanker ginjal pada tahun 2022[3].

CT-scan, yang merupakan singkatan dari *tomografi computer*, dipandang sebagai salah satu metode pencitraan terbaik dan telah menjadi standar untuk analisis serta penilaian tumor di dalam ginjal[4]. CT-scan memberikan gambaran yang lebih detail tentang struktur *vaskular*, memungkinkan untuk membedakan berbagai elemen desain interior seperti dimensi, kepadatan, dan struktur[5] Peningkatan jumlah gambar medis dapat menyulitkan spesialis, yang sering kali mengakibatkan keterlambatan dalam mendeteksi tumor. Hal ini dapat mengakibatkan penundaan dalam pengobatan yang dapat berdampak negatif pada pasien[6]. Oleh karena itu, penggunaan teknologi pencitraan untuk melakukan perbandingan struktur kompleks jaringan ginjal yang sehat dan yang mengalami gangguan menjadi sangat penting[7]. *Convolutional Neural Network* (CNN) adalah jenis jaringan saraf yang secara khusus dirancang untuk menganalisis gambar dan memproses *visi komputer*[8].

CNN telah mencapai pencapaian yang luar biasa dalam memprediksi tumor di berbagai bidang[9]. Namun, untuk mencapai hasil yang optimal, CNN memerlukan dataset yang besar dan berlabel dengan baik, serta variasi kualitas gambar yang baik. *Image enhancement* merupakan salah satu teknik pemrosesan citra yang dapat meningkatkan interpretasi informasi gambar sehingga kualitasnya meningkat. menjadi penting karena dataset citra medis seringkali memiliki resolusi rendah dan tingkat kontras yang tidak seragam[10]. Metode *image enhancement* dapat dilakukan pada dua domain, yaitu *spasial atau frekuensi*, Penyetaraan *histogram* merupakan teknik yang dikenal dalam pemrosesan citra di domain spasial karena efektivitasnya yang tinggi dan kemudahan penerapannya, terutama dalam bidang medis[11]. *Histogram Equalization* (HE) adalah teknik yang menghasilkan gambar di mana tingkat intensitasnya tersebar secara merata di seluruh gambar, mencakup seluruh rentang intensitas. Efek dari proses ini adalah gambar dengan dinamika rentang yang lebih besar mengalami peningkatan kontras[12]. Meningkatkan kontras gambar menggunakan HE memiliki kekurangan, terutama saat digunakan pada citra medis CT-Scan dengan intensitas tinggi. Penerapan HE sederhana dapat mengakibatkan beberapa area gambar CT-Scan menjadi terlalu intens, menyebabkan kehilangan detail yang penting. Dalam kasus ini, CLAHE dapat menjadi solusi yang lebih sesuai[13]

Banyak penelitian telah dilakukan dalam pengolahan citra medis, termasuk klasifikasi kanker kulit menggunakan metode *Support Vector Machine* (SVM) dan *K-Nearest Neighbor* (KNN)[14] Namun, pengembangan terbaru dalam *Machine Learning*, yaitu *Deep Learning*, menjanjikan akurasi yang lebih tinggi. Penelitian yang membandingkan SVM, KNN, dan CNN menunjukkan bahwa CNN mencapai akurasi tertinggi, yaitu 0,942[15]. Penelitian CNN untuk menguji kemampuan model dalam memprediksi jenis penyakit ginjal menggunakan dataset yang diperoleh dari platform Kaggle telah dilakukan. Model CNN mampu mengklasifikasikan citra dengan baik antara ginjal normal dan ginjal kista. Namun, terdapat kesulitan dalam membedakan antara citra ginjal batu dan ginjal tumor karena kemiripan visualnya dengan citra ginjal kista. Hasil akhir dari uji coba menunjukkan tingkat akurasi sebesar 75,17% dengan nilai *f1-score* sebesar 68%[16]. CNN digunakan dalam pengolahan citra medis untuk klasifikasi, segmentasi, dan deteksi[17], Algoritma ini telah diterapkan dalam beberapa penelitian klasifikasi citra medis [18][19]. Oleh karena itu, penelitian ini mengadopsi algoritma CNN untuk melakukan klasifikasi tumor ginjal. Pada tahap preprocessing, dilakukan proses resize

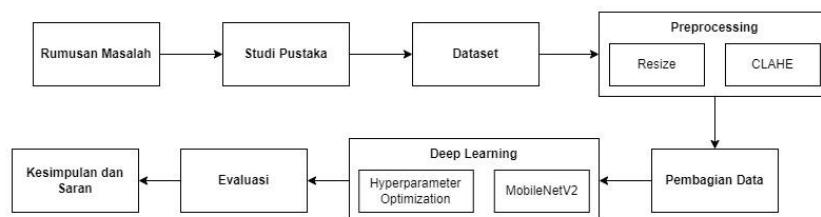
dan penggunaan teknik image enhancement dengan CLAHE untuk meningkatkan kontras pada citra CT-Scan.

II. SIGNIFIKANSI STUDI

Berdasarkan penelitian sebelumnya yang dipublikasikan di Connell University pada 8 April 2024 dengan judul Comparative Analysis of Image Enhancement Techniques for Brain Tumor Segmentation: Contrast, Histogram and Hybrid Approaches. penelitian ini membandingkan algoritma image enhancement diantaranya HE, CLAHE, HE-CLAHE dan CLAHE-HE, dari penelitian ini. dari penelitian ini didapat kan Algoritma CLAHE mencapai akurasi 98,62 dan Dice 99,30 sedikit lebih rendah dibandingkan Algoritma CLAHE-HE dengan akurasi 98,60 dan Dice 99,29. sedangkan algoritma HE mendapatkan akurasi 98,16 dan Dice 99,07 dan HE-CLAHE 98,57 akurasi dan 99,23 Dice. Baik AHE dan CLAHE sama memiliki performa yang baik, algoritma mana yang lebih tepat untuk digunakan pada penelitian tergantung pada aplikasi dan kebutuhan spesifik[20]

Penelitian lain nya mengenai clahe pada tahun 2019 dengan judul Comparative study of Histogram Equalization Enhancement Techniques for Medical Images, penelitian ini membandingkan algoritma image enhancement Adaptive Histogram Equalization (AHE), Histogram Equalization (HE) dan Contras Limited Adaptive Histogram Equalization (CLAHE). Hasil dari penelitian ini didapatkan Algoritma AHE memiliki nilai Entropi yang baik dan Nilai SNR yang stabil akan tetapi AHE mendapatkan nilai SSIM yang buruk. disisi lain Algoritma CLAHE memiliki nilai SIIM terbaik dengan nilai Entropi dan SNR Sedang[11].

Penelitian ini mengeksplorasi Pengaruh Contrast Limited Adaptive Histogram Equalization dalam klasifikasi CT scan tumor ginjal menggunakan deep learning. Untuk mencapai hasil yang optimal, penelitian ini dibagi menjadi beberapa tahap, seperti yang digambarkan dalam gambar berikut.

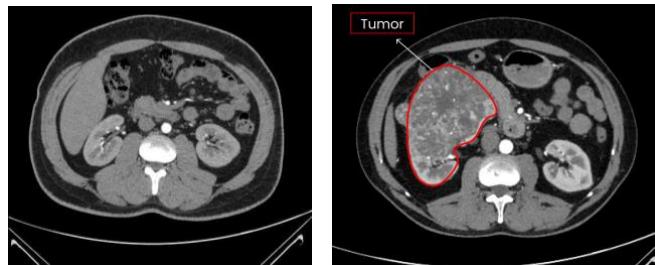


Gambar 1. Metodologi Penelitian

Gambar 1. menggambarkan alur kerja yang Tahapannya meliputi Dataset, preprocessing data, pembagian data, implementasi *deep learning*, dan evaluasi. Tahapan awal adalah preprocessing, pada tahap ini dilakukan *resizing* dan *image enhancement*, untuk memastikan konsistensi data dengan input yang dibutuhkan dalam proses deep learning. Setelah itu, data yang telah diproses dari tahap sebelumnya akan dilatih menggunakan *deep learning*, data yang telah dilatih akan dievaluasi menggunakan metode *confusion matrix*.

A. Dataset

Dataset yang digunakan dalam penelitian ini berasal dari artikel yang dipublikasikan di PubMed pada tahun 2022 dengan judul "Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-Radiography". Dataset original terdiri dari 12.466 data dengan 4 kelas: Normal, kista, batu, dan tumor. dataset dikumpulkan dari rumah sakit di dhaka bangladesh, semua gambar diverifikasi oleh dokter dan ahli teknologi medis untuk memastikan kembali kebenaran data. kumpulan data yang digunakan dalam penelitian ini berjumlah 4.560 gambar CT ginjal, total ada dua kelas. 2.280 gambar kelas nomal, dan 2.280 kelas tumor[21].



Gambar 2 (a) Ginjal Normal

Gambar 2 (b) Ginjal Tumor

Gambar 2 (a) menampilkan citra medis dari ginjal normal, yang telah diperoleh dari dataset terverifikasi. Dataset ini telah dikonfirmasi keakuratannya oleh dokter dan ahli teknologi medis. Sementara itu, Gambar 2 (b) memperlihatkan citra medis dari tumor ginjal, di mana area tumor telah ditandai dengan jelas untuk memudahkan identifikasi.

B. Preprocessing

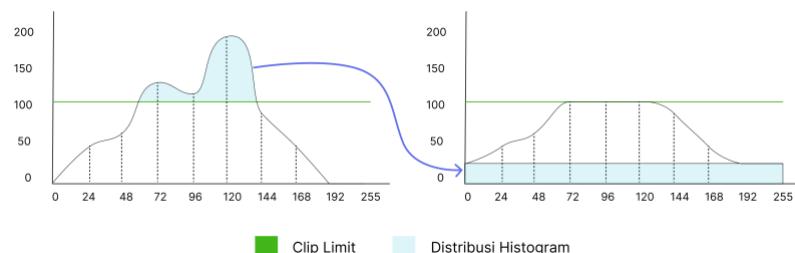
Preprocessing terbagi menjadi dua tahap: *resizing* dan *image enhancement*. Data akan *resize* dan ditingkatkan kontrasnya menggunakan proses *image enhancement* dengan metode CLAHE. CLAHE menggunakan nilai ambang batas yang rendah saat mengubah *histogram*. Teknik ini meningkatkan kualitas gambar dengan meningkatkan kontras, sambil menghindari peningkatan *noise* yang berlebihan dan mengurangi efek bayangan tepi[22] Nilai ambang batas ditentukan dengan menggunakan batas *klip*[23].

1. Resize

Data CT-Scan Ginjal akan diubah ukurannya menjadi 224x224 piksel untuk menyesuaikan dengan input yang diharapkan oleh model MobileNetV2. Model MobileNetV2 dirancang untuk menerima input gambar dengan dimensi 224x224 piksel, meskipun model ini juga dapat menerima input dengan dimensi yang lebih kecil, mulai dari 96x96 piksel[24].

2. Contrast Limited Adaptive Histogram Equalization (CLAHE)

CLAHE diterapkan untuk meningkatkan kontras pada gambar sebelum Deep Learning. Teknik ini membatasi amplifikasi histogram dengan nilai batas (clip limit) untuk mengurangi keabuan gambar. Histogram asli tiap blok gambar dipotong dari atas jika melebihi clip limit. Bagian histogram yang dipotong ini kemudian didistribusikan secara merata ke seluruh rentang piksel dalam histogram.



Gambar 3. Proses pemotongan dan redistribusi histogram (Gabriel Fillipe CC, EURASIP Journal on Image and Video Processing 2019)

Gambar 3, Histogram CLAHE adalah representasi grafis distribusi nilai intensitas piksel dalam gambar yang telah diproses dengan teknik CLAHE. Sumbu X (Nilai Intensitas Piksel) Menunjukkan nilai intensitas piksel dalam gambar, mulai dari 0 (hitam) hingga 255 (putih). Sumbu Y (Jumlah Piksel) Menunjukkan jumlah piksel dalam gambar yang memiliki nilai intensitas piksel yang sesuai dengan nilai pada sumbu X. CLAHE di OpenCV memanfaatkan dua parameter utama: tile grid size dan clip limit. Pertama, tile grid size dan clip limit ditentukan. Kemudian, histogram dibuat untuk setiap tile (kotak kecil) pada gambar. Histogram

tile dipotong berdasarkan clip limit, nilai di atas clip limit didistribusikan kembali ke seluruh histogram[25]. histogram yang telah diubah diterapkan pada gambar untuk meningkatkan kontras.

C. Deep Learning

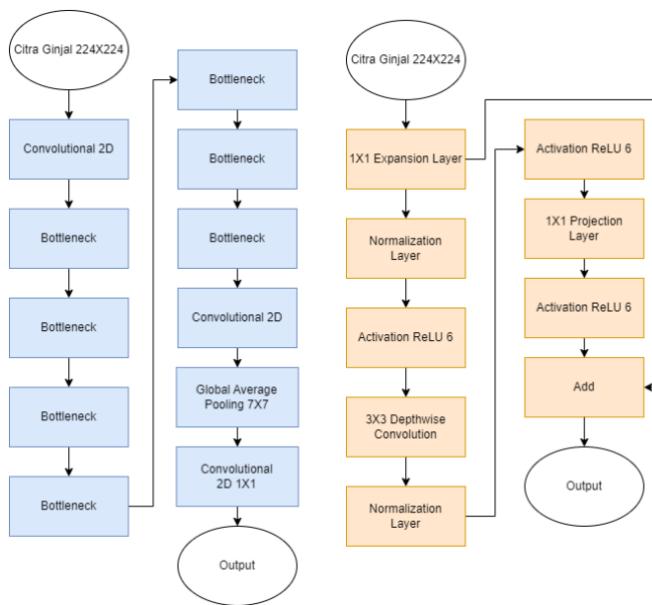
Setelah dataset dilakukan CLAHE dan *resize*, selanjutnya data dibagi menjadi data latih, data validasi, dan data uji. Proses pembagian dataset dibagi dengan rasio 80% dari total dataset digunakan untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Sehingga masing-masing kelas terdiri dari 1824 data latih, 228 data validasi, 228 data uji.

TABEL I
PEMBAGIAN DATASET

Kelas	Dataset Non-CLAHE			Dataset CLAHE		
	Pelatihan (80%)	Validasi (10%)	Pengujian (10%)	Pelatihan (80%)	Validasi (10%)	Pengujian (10%)
Normal	1824	228	228	1824	228	228
Tumor	1824	228	228	1824	228	228

1. MobileNetV2

MobileNetV2 merupakan CNN yang telah digunakan untuk masalah klasifikasi[26], MobileNetV2 memiliki struktur yang terdiri dari beberapa lapisan *konvolusi standar* dengan ukuran *kernel* 3×3 piksel, yang menghasilkan 32 *channel output*. Kemudian, terdapat beberapa lapisan *bottleneck residual* yang menerapkan proses *depthwise separable convolution* dengan ukuran *kernel* 3×3 piksel. Pada bagian akhir dari model dasar ini, terdapat lapisan konvolusi pointwise yang menghasilkan output dengan dimensi $7 \times 7 \times 1024$ piksel, yang ditunjukkan pada gambar 4.



Gambar 4. Arsitektur MobileNetV2

2. Evaluasi

Dalam evaluasi efektivitas jaringan saraf, penggunaan metrik seperti akurasi, presisi, recall, F1 score, dan confusion matrix adalah krusial. Semua metrik ini, beserta rumus matematisnya, diuraikan secara rinci dalam bagian ini untuk memberikan pemahaman yang mendalam tentang performa model[27]. Model akan diuji menggunakan data uji yang telah

dipisahkan sebelumnya. Data uji terbagi menjadi dua kategori, tumor dan normal. Terdapat total 228 data uji untuk kategori tumor dan 228 data uji untuk kategori normal.

1. Accuracy

Accuracy mengukur persentase *instance* yang diklasifikasikan secara benar dari total jumlah *instance* dalam dataset.

$$Akurasi = \frac{TP+FP}{TP+FP+TN+FN} \quad (1)$$

Dalam klasifikasi multikelas, akurasi memperhitungkan semua kelas dan menghitung persentase *instance* yang diklasifikasikan secara benar di semua kelas

2. Precision

Precision menilai kemampuan model dalam mengidentifikasi dengan benar *instance* yang sesuai dengan kelas tertentu dari semua contoh yang diprediksi oleh model sebagai kelas tersebut.

$$Presisi = \frac{TP}{TP+FP} \quad (2)$$

3. Recall

Recall, dikenal sebagai sensitivitas atau tingkat positif actual[28], merupakan metrik evaluasi penting dalam klasifikasi multikelas dalam deep learning. recall menghitung berapa persen ketepatan model dalam memprediksi kelas positif yang sebenarnya.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

4. F1-Score

F1 Skor adalah rata-rata harmonik dari presisi dan recall. Dalam klasifikasi multikelas, skornya dihitung untuk setiap kelas secara terpisah dan kemudian dikumpulkan menjadi satu nilai.

$$F1 - Score = 2 \times \frac{Precision \times recall}{Precision + recall} \quad (4)$$

III. HASIL DAN PEMBAHASAN

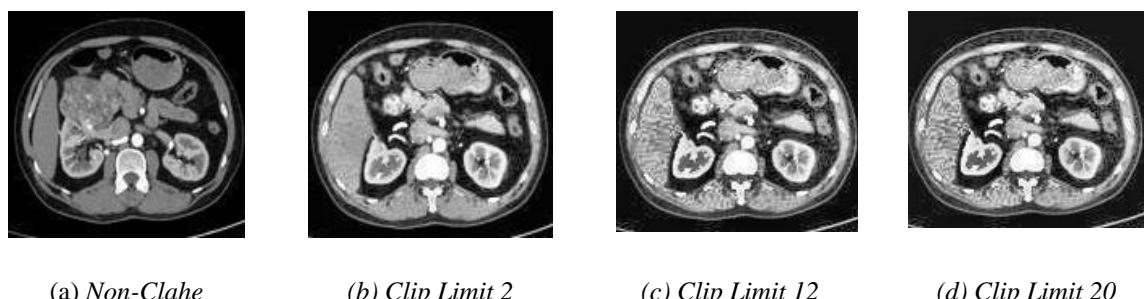
A. Penerapan Contrast Limited Adaptive Histogram Equalization

Proses ini bertujuan untuk menemukan kombinasi optimal dari nilai *Clip limit* yang akan diterapkan pada model *MobileNetV2* selama proses pelatihan data. Penyesuaian model ini ditujukan untuk mencapai kinerja terbaik dalam hal *f1-score* dan *accuracy* pada data validasi asli.

TABEL II
HASIL PEMILIHAN CLIP LIMIT

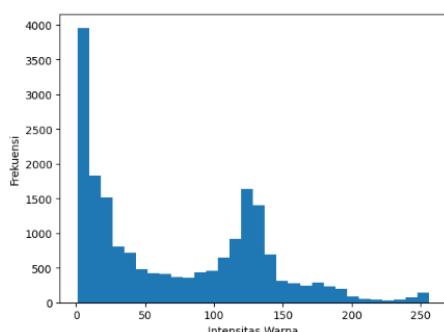
No.	Rasio Dataset	Optimizer	Tile Grid	Clip Limit	F1 Score	Accuracy
1	80:20	Adam	8x8	2	99,13	99,12
2	80:20	Adam	8x8	12	97,55	97,59
3	80:20	Adam	8x8	20	99,56	99,56
4	80:20	SGD	8x8	2	93,72	93,42
5	80:20	SGD	8x8	12	89,58	89,04
6	80:20	SGD	8x8	20	92,69	92,32
7	80:20	Adagrad	8x8	2	88,55	88,60
8	80:20	Adagrad	8x8	12	85,45	85,96
9	80:20	Adagrad	8x8	20	88,07	87,94

Tabel II menampilkan hasil dari pemilihan *clip limit* yang akan digunakan pada pelatihan *clahe*. pelatihan model dilakukan pada 3 Nilai *Clip Limit* yaitu 2, 12, dan 20. Penerapan CLAHE dengan clip limit 20 pada citra medis memungkinkan peningkatan kontras yang lebih besar, memfasilitasi pemisahan struktur citra dengan lebih jelas, seperti membedakan antara jaringan normal dan tumor. Ukuran tile grid 8x8 memperhalus penyesuaian kontras, meningkatkan detail dan visibilitas fitur penting. Kombinasi dataset yang seimbang dan penggunaan optimizer Adam telah terbukti efektif dengan Memperoleh hasil pelatihan dengan *accuracy* tertinggi pada eksperimen ke-3 dengan perolehan *f1-score* 99,56% dan *accuracy* 99,56%.

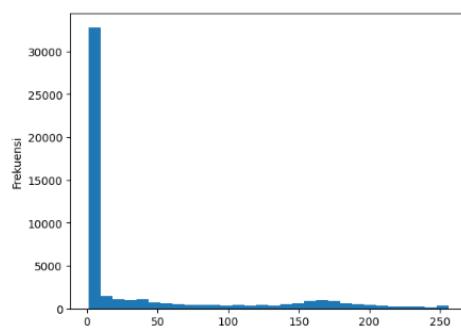


Gambar 5. Perbandingan Citra *Non-CLAHE* dan Citra *CLAHE*

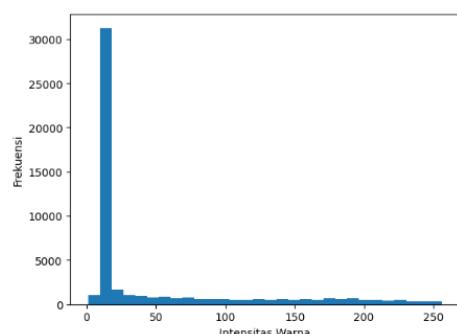
Gambar 5 (a) menunjukkan citra medis ginjal normal tanpa penerapan CLAHE, dan histogram untuk citra tersebut dapat dilihat pada Gambar 6 (a). Sementara itu, Gambar 5 (b) menampilkan citra medis ginjal normal setelah penerapan CLAHE dengan clip limit 2, dengan histogramnya ditampilkan pada Gambar 6 (b). Gambar 5 (c) memperlihatkan citra medis ginjal normal dengan penerapan CLAHE clip limit 12, yang histogramnya dapat dilihat pada Gambar 6 (c). Terakhir, Gambar 5 (d) menunjukkan citra medis ginjal normal setelah penerapan CLAHE dengan clip limit 20, dengan histogramnya ditampilkan pada Gambar 6 (d).



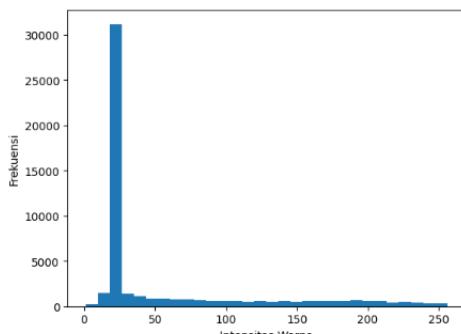
Gambar 6 (a) Histogram Citra ginjal Non *Clahe*



Gambar 6 (b) Histogram Citra ginjal *Clahe* dengan *Clip limit* 2



Gambar 6 (a) Histogram Citra ginjal Non *Clahe* dengan *Clip Limit* 12



Gambar 6 (a) Histogram Citra ginjal Non *Clahe* dengan *Clip Limit* 20

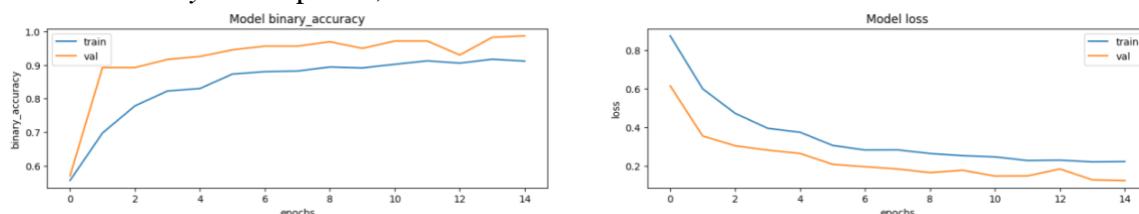
B. Proses Training

Model MobileNetV2 dari TensorFlow akan dilatih untuk mengenali citra dengan baik. Data dibagi menjadi 80% untuk pelatihan, 20% untuk validasi dan uji. Model dioptimalkan dengan 3 optimizer (Adam, SGD, Adagrad) dan 3 learning rate (0.01, 0.001, 0.0001) untuk mencari kombinasi terbaik. Pelatihan berlangsung selama 50 epoch, dan dihentikan jika akurasi validasi tidak meningkat selama 10 epoch berturut-turut (early stopping). Performa model dievaluasi dengan precision, recall, f1-score, dan accuracy, dihitung dari confusion matrix.

TABEL III
HASIL TRAIN DATASET NON-CLAHE

NO	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
1	Adam	0,01	0.3200	0.8972	0.0582	0.9868
2	Adam	0,001	0.2209	0,9117	0.1224	0.9868
3	Adam	0,0001	0.6146	0.6993	0.4011	0.8570
4	SGD	0,01	0.3703	0.8366	0.1725	0.9518
5	SGD	0,001	0.4290	0.7950	0.3184	0.9145
6	SGD	0,0001	0.7635	0.6102	0.5112	0.8377
7	Adagrad	0,01	0.3122	0.8662	0.2105	0.9605
8	Adagrad	0,001	0.7650	0.6102	0.5269	0.7763
9	Adagrad	0,0001	1.0915	0.4989	0.7453	0.4605

Tabel III menampilkan pelatihan model menggunakan dataset *non-clahe*. Proses pelatihan dilakukan dengan variasi *hyperparameter* dan *Learning Rate* yang berbeda, dengan iterasi hingga 50 epoch. Eksperimen kedua menunjukkan hasil pelatihan dengan *validation binary accuracy* tertinggi untuk dataset *non-clahe*, dengan *training accuracy* mencapai 91,17% dan *validation accuracy* mencapai 98,68%.



Gambar 7. Grafik Pelatihan Dataset Non-Clahe

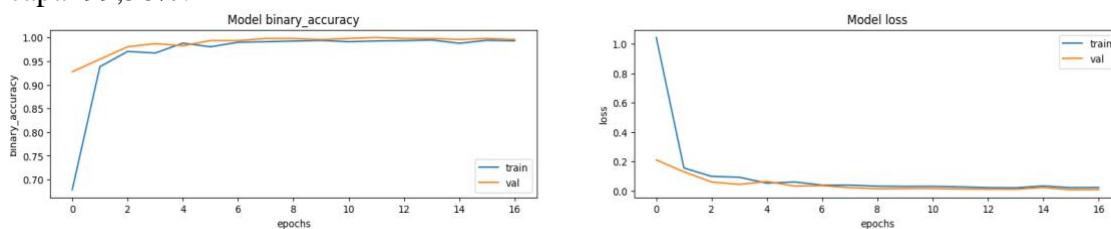
Gambar 7 menunjukkan grafik pelatihan untuk dataset *non-clahe* pada percobaan ke-2 menggunakan *optimizer Adam* dengan *learning rate* 0.001. Pada grafik terdapat garis biru yang menunjukkan *binary accuracy* dan garis oranye menunjukkan validasi. Eksperimen ini mendapatkan hasil *training binary accuracy* 0.9117 dan *validation binary accuracy* 0.9868. menunjukkan peningkatan performa dan minimnya overfitting.

TABEL IV
HASIL TRAIN DATASET CLAHE

NO	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
1	Adam	0,01	0.0238	0.9929	0.0096	0.9956
2	Adam	0,001	0.0811	0.9838	0.0786	0.9868
3	Adam	0,0001	0.2283	0.9397	0.2097	0.9474
4	SGD	0,01	0.0853	0.9756	0.0691	0.9846
5	SGD	0,001	0.1806	0.9454	0.1656	0.9518
6	SGD	0,0001	0.4352	0.8259	0.3912	0.8991

NO	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
7	Adagrad	0,01	0.1154	0.9775	0.1030	0.9868
8	Adagrad	0,001	0.4511	0.8161	0.4380	0.8421
9	Adagrad	0,0001	0.7670	0.4978	0.7188	0.4846

Tabel IV menampilkan pelatihan model menggunakan dataset CLAHE. Proses pelatihan dilakukan dengan *variasi hyperparameter* dan *Learning Rate* yang berbeda, dengan iterasi hingga 50 epoch. Eksperimen pertama menunjukkan hasil pelatihan dengan *training accuracy* untuk dataset CLAHE, dengan *training accuracy* mencapai 99,29% dan *validation accuracy* mencapai 99,56%.



Gambar 8. Grafik Pelatihan Dataset *Clahe*

Gambar 8 menunjukkan grafik pelatihan untuk dataset *clahe* pada percobaan ke-2 menggunakan *optimizer Adam* dengan *learning rate* 0.001. pada grafik terdapat garis biru yang menunjukkan *binary accuracy* dan garis oranye menunjukkan validasi, Eksperimen ini mendapatkan hasil *training binary accuracy* 0.9929 dan *validation binary accuracy* 0.9956. menunjukkan peningkatan performa dan minimnya overfitting.

C. Pengujian Model

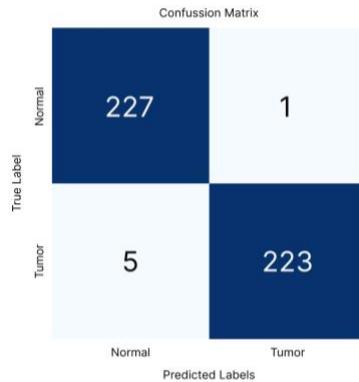
Setelah menyelesaikan pelatihan model dengan dataset *non-clahe* dan dataset yang telah ditingkatkan kontrasnya menggunakan CLAHE, langkah berikutnya adalah menguji model menggunakan dataset pengujian. Pengujian ini akan mencakup semua model yang telah dilatih dengan kedua jenis dataset tersebut. Evaluasi kinerja model akan dilakukan dengan menganalisis confusion matrix, memperhatikan nilai akurasi, presisi, recall, dan f1-score, serta hasil prediksi untuk setiap kelas.

TABEL V
HASIL PENGUJIAN MENGGUNAKAN DATASET NON-CLAHE DAN DATASET CLAHE

No.	Rasio Dataset	Dataset	Optimizer	Learning Rate	Accuracy	Precision	Recall	F1-Score
1	80:20	Non CLAhe	Adam	0.01	98.68	99.55	97.81	98.67
2	80:20	Non CLAhe	Adam	0.001	53.95	56.16	35.96	43.85
3	80:20	Non CLAhe	Adam	0.0001	88.82	88.31	89.47	88.89
4	80:20	Non CLAhe	SGD	0.01	96.93	94.21	100.00	97.02
5	80:20	Non CLAhe	SGD	0.001	91.89	89.30	95.18	92.14
6	80:20	Non CLAhe	SGD	0.0001	92.14	81.57	91.23	86.13
7	80:20	Non CLAhe	Adagrad	0.01	97.15	96.14	98.25	97.18
8	80:20	Non CLAhe	Adagrad	0.001	80.48	81.17	79.39	80.27
9	80:20	Non CLAhe	Adagrad	0.0001	44.30	44.25	43.86	44.05
10	80:20	CLAHE	Adam	0.01	99.56	99.13	100.00	99.56

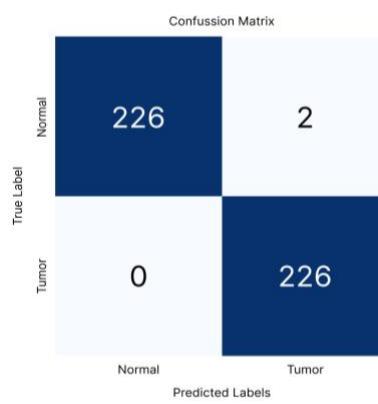
No.	Rasio Dataset	Dataset	Optimizer	Learning Rate	Accuracy	Precision	Recall	F1-Score
11	80:20	CLAHE	Adam	0.001	98.46	97.02	100.00	98.49
12	80:20	CLAHE	Adam	0.0001	95.61	96.43	94.74	95.58
13	80:20	CLAHE	SGD	0.01	99.12	99.56	98.68	99.12
14	80:20	CLAHE	SGD	0.001	98.46	97.02	100.00	98.49
15	80:20	CLAHE	SGD	0.0001	87.61	88.16	91.83	83.77
16	80:20	CLAHE	Adagrad	0.01	99.12	98.70	99.56	99.13
17	80:20	CLAHE	Adagrad	0.001	86.62	85.84	87.72	86.77
18	80:20	CLAHE	Adagrad	0.0001	63.60	62.50	67.98	65.13

Tabel V merupakan hasil pengujian yang dilakukan menggunakan data uji yang belum pernah digunakan sebelumnya. Hasil pengujian pada dataset *non-clahe* mencapai akurasi tertinggi pada percobaan ke-1, sedangkan pada dataset clahe mencapai akurasi tertinggi pada percobaan ke-10.



Gambar 9. *Confusion Matrix* Dataset Non-Clahe

Gambar 9. Predicted Labels menunjukkan label yang diprediksi oleh model, sementara True Labels menunjukkan label yang sebenarnya. Model ini sangat akurat dalam memprediksi kedua kelas, hanya membuat 2 kesalahan prediksi di mana data Normal diprediksi sebagai Tumor, dan tidak ada kesalahan prediksi untuk data Tumor yang diprediksi sebagai Normal. Hasil pengujian dari percobaan ke-1 dapat dilihat pada Gambar 8 yang menunjukkan hasil *confusion matrix* dengan *accuracy* 98.68%, *precision* 99.55%, *recall* 97.81%, *f1-score* 98.67%.



Gambar 10. *Confusion Matrix* Dataset Contrast Limited Adaptive Histogram Equalization

Gambar 10. Predicted Labels menunjukkan label yang diprediksi oleh model, sementara True Labels menunjukkan label yang sebenarnya. Model ini sangat akurat dalam memprediksi kedua kelas, hanya membuat 2 kesalahan prediksi di mana data Normal diprediksi sebagai Tumor, dan tidak ada kesalahan prediksi untuk data Tumor yang diprediksi sebagai Normal, Hasil pengujian dari percobaan ke-10 dapat dilihat pada Gambar 9 yang menunjukkan hasil *confusion matrix* dengan *accuracy* 99.56%, *precision* 99.13%, *recall* 100%, *f1-score* 99.56%.

D. Perbandingan Hasil Dataset NON-CLAHE dan CLAHE

setelah menguji dua jenis citra, yaitu citra Non-CLAHE dan citra yang telah ditingkatkan kontrasnya menggunakan metode CLAHE. Dilakukan perbandingan antara keduanya, tujuannya adalah untuk mengevaluasi dampak penggunaan CLAHE dalam meningkatkan kualitas citra serta memahami perbedaan antara keduanya dalam konteks pengolahan citra dan analisis visual. CLAHE terbukti meningkatkan akurasi, presisi, dan recall dibandingkan citra Non-CLAHE, menunjukkan bahwa CLAHE efektif dalam meningkatkan performa model pengenalan citra. CLAHE mengatasi kontras rendah yang terlihat pada citra Non-CLAHE, menghasilkan gambar yang lebih tajam dan jelas. Namun, perlu dicatat bahwa penggunaan CLAHE tidak selalu menghasilkan hasil yang lebih baik dalam setiap situasi, dan pengaturan parameter yang tepat sangat penting untuk menghindari peningkatan noise dalam citra. Perbandingan ini menunjukkan bahwa CLAHE lebih cocok untuk citra dengan kontras rendah, terutama dalam bidang citra medis di mana teknik ini dapat sangat berguna untuk meningkatkan visualisasi detail anatomi. Keseluruhan, perbandingan antara citra CLAHE dan asli penting dalam pengambilan keputusan terkait pengolahan citra untuk memilih metode yang paling sesuai dengan tujuan yang diinginkan..



Gambar 11. Grafik Perbandingan Pengujian Non-Clahe dan Clahe

Gambar 11. menampilkan grafik perbandingan dari hasil pengujian model dataset *non-clahe* dan dataset *clahe*. Dari grafik tersebut menunjukkan bahwa model dengan dataset CLAHE memiliki performa tertinggi yaitu, *accuracy* 99.56%, *precision* 99.13%, *recall* 100%, *f1-score* 99.56%.. sedangkan model dengan dataset *non-clahe* menghasilkan performa sedikit lebih rendah yaitu, *accuracy* 98.68%, *precision* 99.55%, *recall* 97.81%, *f1-score* 98.67%.

IV. KESIMPULAN

Klasifikasi citra ginjal normal dan tumor dilakukan menggunakan *CNN MobileNetV2*. Dataset yang digunakan terdiri dari 2.280 CT scan normal dan 2.280 CT scan tumor. Kinerja model dievaluasi menggunakan *confusion matrix* untuk memperoleh nilai *precision*, *recall*, *f1-score*, dan *accuracy*. Hasil percobaan pada dataset *non-clahe* menunjukkan bahwa hasil terbaik diperoleh pada rasio pembagian 80:20 dengan *optimizer Adam* dan *learning rate* 0,01, menghasilkan *f1-score* sebesar 98,67% dan *accuracy* 98,68%. Sementara itu, hasil terbaik dengan data yang telah diproses menggunakan *CLAHE* diperoleh dengan kombinasi *clip limit* 20 dan *tile grid* 8x8, menggunakan *optimizer Adam* dengan *learning rate* 0,01, menghasilkan *f1-score* sebesar 99,56% dan *accuracy* 99,56%. Dengan demikian, dapat disimpulkan bahwa penggunaan CLAHE meningkatkan performa model dalam mengklasifikasikan citra CT scan.

Hasil ini sangat penting dalam konteks eksperimental karena menunjukkan potensi untuk mendiagnosis tumor ginjal dengan lebih akurat dan efisien, yang dapat meningkatkan hasil diagnosa pasien dan mengurangi risiko kesalahan diagnosa. Hal ini sangat penting bagi ahli radiologi, karena dapat membantu mereka dalam membuat diagnosis yang lebih tepat dan cepat. Disarankan untuk mempertimbangkan penambahan jumlah data citra yang dilatih, variasi kombinasi clip limit dan tile grid, serta eksplorasi penggunaan kombinasi metode peningkatan citra lainnya seperti Contrast Stretching atau Gamma Correction. Penelitian lebih lanjut diperlukan untuk menguji efektivitas model ini dalam kondisi klinis nyata.

REFERENCES

- [1] V. V. Patel, A. R. Yadav, P. Jain, and L. R. Cenkeramaddi, “A Systematic Kidney Tumor Segmentation and Classification Framework using Adaptive and Attentive-based Deep Learning Networks with Improved Crayfish Optimization Algorithm,” *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3410833.
- [2] L. Corbat, J. Henriet, Y. Chaussy, and J.-C. Lapayre, “Fusion of multiple segmentations of medical images using OV 2 ASSION and Deep Learning methods: Application to CT-Scans for tumoral kidney,” 2020.
- [3] World Cancer Research Fund International, “Kidney cancer statistics,” <https://www.wcrf.org/cancer-trends/kidney-cancer-statistics/>, 2020. Accessed: May 09, 2024. [Online]. Available: <https://www.wcrf.org/cancer-trends/kidney-cancer-statistics/>
- [4] Z. Riaz, B. Khan, S. Abdullah, S. Khan, and M. S. Islam, “Lung Tumor Image Segmentation from Computer Tomography Images Using MobileNetV2 and Transfer Learning,” *Bioengineering*, vol. 10, no. 8, Aug. 2023, doi: 10.3390/bioengineering10080981.
- [5] G. M. Ghiggeri *et al.*, “A two-stage renal disease classification based on transfer learning with hyperparameters optimization,” croatia, Apr. 2023. doi: 10.3389/fmed.2023.1106717.
- [6] W. Alhazmi and T. Turki, “Applying Deep Transfer Learning to Assess the Impact of Imaging Modalities on Colon Cancer Detection,” *Diagnostics*, vol. 13, no. 10, May 2023, doi: 10.3390/diagnostics13101721.
- [7] S. Singh, V. Saxena, and B. Bhimrao, “A Fine Tuned Pre-trained Model for Classification of Brain Tumor using Magnetic Resonance Imaging.” [Online]. Available: <https://www.researchgate.net/publication/378240870>
- [8] J. Kers *et al.*, “Deep learning-based classification of kidney transplant pathology: a retrospective, multicentre, proof-of-concept study,” *Lancet Digit Health*, vol. 4, no. 1, pp. e18–e26, Jan. 2022, doi: 10.1016/S2589-7500(21)00211-9.
- [9] T. Mahmood, J. Li, Y. Pei, and F. Akhtar, “An automated in-depth feature learning algorithm for breast abnormality prognosis and robust characterization from mammography images using deep transfer learning,” *Biology (Basel)*, vol. 10, no. 9, Sep. 2021, doi: 10.3390/biology10090859.
- [10] S. Saifullah and R. Drezewski, “Modified Histogram Equalization for Improved CNN Medical Image Segmentation,” in *Procedia Computer Science*, Elsevier B.V., 2023, pp. 3021–3030. doi: 10.1016/j.procs.2023.10.295.
- [11] A. N. Ismael, N. H. Ajam, and Z. S. Jumaa, “Comparative study of Histogram Equalization Enhancement Techniques for Medical Images,” *Int J Sci Eng Res*, vol. 10, no. 6, 2019, [Online]. Available: <http://www.ijser.org>

- [12] N. Salem, H. Malik, and A. Shams, “Medical image enhancement based on histogram algorithms,” in *Procedia Computer Science*, Elsevier B.V., 2019, pp. 300–311. doi: 10.1016/j.procs.2019.12.112.
- [13] M. Kyriakopoulou, “Histogram Equalization on Medical Images: CLAHE implementation on CT images,” Greece, May 2020. Accessed: Jun. 15, 2024. [Online]. Available: <https://eclass.hmu.gr/modules/document/index.php?course=TP283&download=/6069a1b4Lu7B/6069a1cegUDz.pdf>
- [14] M. Faruk and N. Nafi’iyah, “Telematika Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur, Fitur Warna Citra Menggunakan SVM dan KNN,” vol. 13, no. 2, pp. 100–109, 2020, doi: 10.35671/telematika.v13i2.987.
- [15] M. F. Naufal, “Analisis Perbandingan Algoritma SVM, KNN, Dan CNN Untuk Klasifikasi Citra Cuaca”, doi: 10.25126/jtiik.202184553.
- [16] F. Aulia *et al.*, “Implementasi Algoritma Convolutional Neural Network untuk Mendeteksi Penyakit Ginjal Implementation Of Convolutional Neural Network For Detecting Kidney Disease.” [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- [17] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Analisis Citra Medis,” Dec. 2022.
- [18] D. Abdillah Salafy, F. Yanto, S. Agustian, and F. Insani, “KLIK: Kajian Ilmiah Informatika dan Komputer Perbandingan Klasifikasi Citra CT-Scan Kanker Paru-Paru Menggunakan Image Enhancement CLAHE Pada EfficientNet-B0,” *Media Online*, vol. 4, no. 3, pp. 1651–1659, 2023, doi: 10.30865/klik.v4i3.1514.
- [19] A. Salam, F. Yanto, S. Agustian, and S. Ramadhani, “KLIK: Kajian Ilmiah Informatika dan Komputer Perbandingan Klasifikasi Citra CT-Scan Kanker Paru-Paru Menggunakan Contrast Stretching Pada CNN dengan EfficientNet-B0,” *Media Online*, vol. 4, no. 3, pp. 1341–1351, 2023, doi: 10.30865/klik.v4i3.1448.
- [20] S. Saifullah, A. Pranolo, and R. Dreżewski, “Comparative Analysis of Image Enhancement Techniques for Brain Tumor Segmentation: Contrast, Histogram, and Hybrid Approaches,” Apr. 2024. doi: <https://doi.org/10.1051/e3sconf/202450101020>.
- [21] M. N. Islam, M. Hasan, M. K. Hossain, M. G. R. Alam, M. Z. Uddin, and A. Soylu, “Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography,” *Sci Rep*, vol. 12, no. 1, Dec. 2022, doi: 10.1038/s41598-022-15634-4.
- [22] S. Saifullah, “Analisis Perbandingan HE Dan CLAHE pada Image Enhancement dalam Proses Segmenasi Citra Untuk Deteksi Fertilitas Telur,” Yogyakarta, Mar. 2020.
- [23] J. W. Gichoya *et al.*, “AI recognition of patient race in medical imaging: a modelling study,” *Lancet Digit Health*, vol. 4, no. 6, pp. e406–e414, Jun. 2022, doi: 10.1016/S2589-7500(22)00063-2.
- [24] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” Jan. 2019, doi: <https://doi.org/10.48550/arXiv.1801.04381>.
- [25] F. M. Hana and I. D. Maulida, “Analysis of contrast limited adaptive histogram equalization (CLAHE) parameters on finger knuckle print identification,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1764/1/012049.
- [26] W. Hastomo, A. Satyo Bayangkari Karno, E. Sestri, E. Karla, and D. Arif, “Arsitektur MobilenetV2 Untuk Mendeteksi Citra X-Ray Covid-19,” vol. 5, no. 2, pp. 295–303, 2022, doi: 10.31764/justek.vXiY.ZZZ.

- [27] M. Pandiyarajan and R. S. Valarmathi, "Deep Learning Techniques in Classification of Stages in Dementia: An Ensemble Approach," *Journal of Advanced Research in Applied Sciences and Engineering Technology*, vol. 36, no. 1, pp. 131–146, Jun. 2024, doi: 10.37934/araset.36.1.131146.
- [28] A. Tedyyana, O. Ghazali, and O. W. Purbo, "Machine learning for network defense: automated DDoS detection with telegram notification integration," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 34, no. 2, p. 1102, May 2024, doi: 10.11591/ijeecs.v34.i2.pp1102-1109.