

Pengaruh Image Enhancement Contrast Stretching dalam Klasifikasi CT-Scan Tumor Ginjal Menggunakan Deep Learning

M Ilham Hatta¹, Febi Yanto², Iis Afrianty³, Liza Afriyanti^{1,2,3,4}
Program Studi Teknik Informatika

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

E-mail: 11950111703@students.uin-suska.ac.id¹, febiyanto@uin-suska.ac.id^{*2}, iis.afrianty@uin-suska.ac.id³, liza.afriyanti@uin-suska.ac.id⁴

Abstract - The kidneys are essential organs in the human body, crucial for removing metabolic waste. Impaired kidney function can lead to an irreversible decline, known as chronic kidney disease. Another condition affecting the kidneys is kidney tumors, which are the third most common type of tumor after prostate and bladder tumors, with around 208,500 cases (2%) of all cancer cases globally. This research employs the Image Enhancement Contrast Stretching technique to enhance CT scan images of kidney tumors for deep learning classification using the EfficientNet-B0 architecture. The dataset is divided into 80% for training, 10% for validation, and 10% for testing, resulting in 1824 training, 228 validation, and 228 test data points per class. Hyperparameters include Adamax and RAdam optimizers with learning rates of 0.01, 0.001, and 0.0001. The highest performance was achieved using the Image Enhancement Contrast Stretching technique with the Adamax optimizer and a learning rate of 0.01, yielding 99.92% accuracy, 99.85% precision, 100% recall, and a 99.92% F1-score. For the original dataset with the same optimizer and learning rate, the best performance was 99.12% accuracy, 98.28% precision, 100% recall, and a 99.13% F1-score. This technique has proven to enhance kidney tumor classification models.

Keywords: Classification, Contrast Stretching, Deep Learning, EfficientNet-B0, Kidney Tumor.

Intisari - Ginjal adalah organ vital dalam tubuh manusia yang berperan utama dalam mengeluarkan sisa-sisa metabolisme tubuh. Gangguan fungsi ginjal dapat menyebabkan penurunan fungsi ginjal dan tidak dapat dipulihkan yang dikenal dengan ginjal kronis. Penyakit lainnya yang dapat terjadi pada ginjal adalah tumor ginjal. Tumor ginjal adalah tumor ketiga paling umum setelah tumor prostat dan kandung kemih, dengan sekitar 208.500 kasus (2%) dari seluruh kasus kanker di dunia. Penelitian ini menggunakan teknik Image Enhancement Contrast Stretching untuk meningkatkan kualitas citra CT-Scan tumor ginjal dalam klasifikasi deep learning dengan arsitektur EfficientNet-B0. Dataset dibagi dengan rasio 80% dari total dataset digunakan untuk pelatihan model, 10% untuk validasi, dan 10% untuk pengujian. Sehingga masing-masing kelas terdiri dari 1824 data latih, 228 data validasi, 228 data uji. Hyperparameter yang digunakan meliputi optimizer Adamax dan RAdam dengan learning rate 0.01, 0.001, dan 0.0001. Hasilnya, penggunaan teknik Image Enhancement Contrast Stretching dengan optimizer Adamax dan learning rate 0.01 menghasilkan performa tertinggi dengan akurasi 99,92%, presisi 99,85%, recall 100%, dan F1-score 99,92%. Untuk dataset original dengan optimizer Adamax dan learning rate 0.01, performa tertinggi adalah akurasi 99.12%, presisi 98.28%, recall 100%, dan F1-score 99.13%. Teknik Image Enhancement Contrast Stretching terbukti meningkatkan performa model klasifikasi tumor ginjal.

Kata Kunci: Contrast Stretching, Deep Learning, EfficientNet-B0, Klasifikasi, Tumor Ginjal.

I. PENDAHULUAN

Ginjal adalah organ vital dalam tubuh manusia yang berperan utama dalam mengeluarkan sisa-sisa metabolisme tubuh, seperti ureum, kreatinin, dan asam urat. Gangguan fungsi ginjal dapat menyebabkan penurunan fungsi ginjal yang progresif dan tidak dapat dipulihkan, dikenal sebagai penyakit ginjal kronis.[1]. Penyakit lainnya yang dapat terjadi pada ginjal adalah tumor

ginjal[2]. Tumor ginjal adalah tumor ketiga paling umum setelah tumor prostat dan kandung kemih, dengan sekitar 208.500 kasus (2%) dari seluruh kasus kanker di dunia. Di Indonesia, insiden kanker ginjal adalah 3 kasus per 100.000 penduduk dengan rasio pria terhadap wanita sebesar 3,2:1. Pasien yang menunjukkan satu atau lebih temuan klinis harus dicurigai menderita tumor ginjal[3].

Pencitraan yang digunakan untuk mendeteksi, mendiagnosis, dan menilai karakteristik tumor ginjal meliputi ultrasound, CT scan, dan Magnetic Resonance Imaging (MRI). CT scan dianggap sebagai metode yang sangat akurat untuk mendeteksi massa ginjal, dengan sensitivitas mencapai 100% dan spesifisitas 95%[4]. Penelitian dalam bidang pengolahan citra medis menunjukkan bahwa teknik Image Enhancement, khususnya Contrast Stretching (CS), dapat meningkatkan kualitas citra CT-scan dengan peningkatan rentang dinamis gambar dengan peregangan kontras linier melalui pemodelan histogram dan fungsi transformasi intensitas. Penelitian tentang implementasi contrast stretching pada citra medis telah dilakukan. Berdasarkan analisis kualitas citra dan evaluasi kuantitatif, ditemukan bahwa metode kontras stretching memberikan hasil yang signifikan secara visual lebih baik untuk citra MRI dibandingkan dengan metode equalisasi histogram dan equalisasi histogram adaptif. Metode contrast stretching memiliki nilai MSE terendah, yaitu 0,00346[5]. penelitian contrast stretching lainnya menunjukkan bahwa metode kontras stretching dapat diterapkan untuk memperbaiki citra greyscale dan citra RGB (true color) yang memiliki kontras rendah atau cenderung gelap. Hasilnya menunjukkan bahwa metode kontras stretching efektif dalam meningkatkan kualitas citra dengan cara meratakan histogram yang awalnya terfokus pada satu area tertentu, sehingga informasi dalam citra menjadi lebih jelas dibandingkan dengan citra aslinya[6]. Rentang intensitas: nilai intensitas rendah dan tinggi dihitung secara heuristik, dan topeng bentuk kuadrat dipindahkan untuk membersihkan gambar [7]. Penelitian lainnya tentang pengolahan citra mamografi menggunakan metode contrast stretching telah dilakukan. Terbukti dapat meratakan sebaran intensitas sehingga kontras citra mamografi semakin meningkat.[8]

Peneliti terdahulu telah mendapatkan hasil yang memuaskan dari penggunaan Convolutional Neural Network (CNN) sebagai metode pengolahan citra medis seperti klasifikasi, deteksi, segmentasi, dan peningkatan citra [9]. Arsitektur EfficientNet-B0, sebagai salah satu varian terkini dari model CNN telah menunjukkan keunggulannya. Penelitian CNN untuk melakukan perbandingan akurasi arsitektur dari EfficientNet-B0, AlexNET dan DarkNet-53 dari data rambu lalu lintas pada dataset German Traffic Signs Recognition Benchmark (GTSRB). Hasil menunjukkan, Arsitektur EfficientNet-B0 mengungguli arsitektur lainnya dengan persentase akurasi EfficientNet-B0 98,64%, AlexNET 97,45% dan DarkNet-53 94,69%[10]. Penelitian EfficientNet-B0 lainnya tentang klasifikasi citra daging sapi, daging babi, dan oplosan telah dilakukan. Hasil menunjukkan bahwa model dengan rasio pembagian data 90:10 mencapai akurasi tertinggi menggunakan citra asli, optimizer Adamax, aktivasi tersembunyi Swish, dan learning rate 0,1, dengan nilai akurasi mencapai 97,11%, presisi 97,14%, recall 97,11%, dan F1-Score 97,11%. Di sisi lain, untuk rasio pembagian data 80:20, model yang menggunakan citra augmentasi, optimizer RAdam, aktivasi tersembunyi ReLU, dan learning rate 0,01, mencapai akurasi tertinggi sebesar 95,06%, presisi 95,12%, recall 95,06%, dan F1-Score 95,12%[11]. Penelitian dibidang medis tentang sistem pengenalan covid-19 menggunakan arsitektur EfficientNet-B0 secara signifikan meningkatkan akurasi prediksi dibandingkan dengan penggunaan arsitektur ResNet-18. Penelitian CNN lainnya tentang kombinasi segmentasi dan klasifikasi tumor ginjal dapat mencapai tingkat akurasi 99,5% untuk tumor jinak dan ganas[12]. Penelitian CNN tumor ginjal lainnya yang telah dilakukan. Hasil menunjukkan akurasi model untuk mengenali citra (Normal/Tumor dan Jinak/Malignant) model VGG16, ResNet50, dan 2D-CNN didapatkan akurasi 60%, 96%, dan 97%[13]. Penelitian CNN yang membandingkan penggunaan augmentasi data dan tanpa augmentasi data telah dilakukan. Hasil penelitian menunjukkan akurasi tanpa augmentasi hanya

mencapai akurasi 82% sampai 96%. sedangkan setelah augmentasi data berada diantara 97% sampai 100%. Penelitian tentang deteksi dan klasifikasi tumor otak menggunakan CNN didapatkan hasil, model dapat mendeteksi Tumor dan Tidak Tumor dengan akurasi 96,08% dan F1-Score 97,3%[14]. Penelitian yang CNN lainnya yang telah dilakukan mengenai klasifikasi Covid-19 dari citra ct-scan paru-paru CNN yang dilakukan dengan dataset berjumlah 3216 data dalam format JPG. Hasil pengujian menunjukkan nilai akurasi sebesar 100%. Namun, ketika dilakukan pengujian terhadap data baru yang tidak termasuk dalam proses pengujian dan pelatihan, terjadi kasus di mana citra yang seharusnya diklasifikasikan sebagai Covid-19 diprediksi sebagai normal. Hal ini mungkin disebabkan oleh kualitas yang sangat baik dari data latih dan uji yang digunakan, yang mempengaruhi hasil klasifikasi saat menghadapi citra-citra yang berbeda.[15]

Banyak penelitian tentang CNN dan penggunaan Image Enhancement untuk meningkatkan kualitas citra, termasuk penelitian untuk melakukan prediksi terhadap citra MRI tumor otak menggunakan CNN dan Contrast Stretching dengan arsitektur MobileNetV2 dengan hasil akurasi sebesar 97,47% dan 98,92%.[16] Sementara itu penelitian untuk identifikasi Pneumonia dari hasil rontgen dada menggunakan 8 model arsitektur dari CNN dan CLAHE didapatkan nilai akurasi tertinggi yaitu model 35 layer dengan akurasi 82.53%[17]. Penelitian lainnya tentang penggunaan image enhancement pada CNN tentang membandingkan klasifikasi kanker paru-paru dengan menggunakan teknik image enhancement CLAHE. Model yang dilatih dengan menggunakan data asli mencapai nilai F1-Score sebesar 81,69% dan akurasi 81,76%, sementara model yang menggunakan data hasil CLAHE mencapai nilai F1-Score sebesar 84,45% dan akurasi 84,71%.[18]

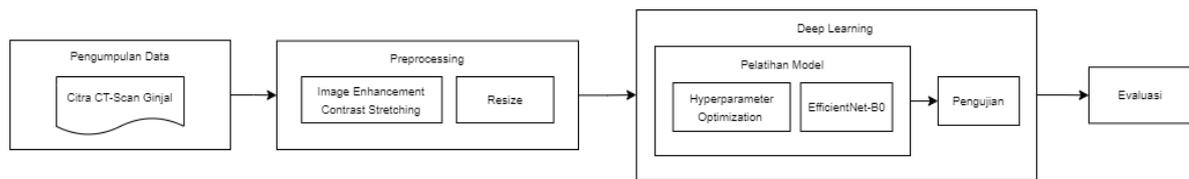
Berdasarkan latar belakang dan permasalahan yang telah diuraikan diatas, maka pada penelitian ini akan melakukan penelitian untuk mengetahui pengaruh penggunaan teknik image enhancement contrast stretching dalam klasifikasi citra ct-scan tumor ginjal menggunakan Convolutional Neural Network (CNN) dengan arsitektur EfficientNet-B0.

II. SIGNIFIKANSI STUDI

Penelitian ini mengacu pada beberapa studi, termasuk yang dilakukan oleh Supiyanto dan Titik Suparwati mengenai perbaikan citra menggunakan metode Contrast Stretching. Hasil studi tersebut menunjukkan bahwa metode *contrast stretching* dapat diterapkan untuk memperbaiki citra *greyscale* dan citra RGB (*true color*) dengan kontras rendah atau citra gelap. Selain itu, metode ini dapat meningkatkan kualitas citra dengan meratakan histogram yang awalnya terkonsentrasi pada area tertentu, sehingga informasi dalam citra menjadi lebih jelas dibandingkan dengan citra asli[6].

Penelitian lain tentang penggunaan metode contrast stretching dilakukan oleh Tio Ramadhan, dkk. Hasil dari penelitian menunjukkan bahwa metode contrast stretching dapat diterapkan untuk meningkatkan kualitas citra dengan mengonversi nilai RGB setiap piksel citra menjadi bentuk grayscale, sehingga diperoleh nilai grayscale yang baru. Proses contrast stretching ini efektif untuk memperbaiki citra digital dengan kontras rendah, membuat citra menjadi lebih cerah dan objek tampak lebih jelas. Penelitian ini mengaplikasikan proses contrast stretching pada sampel citra 1 hingga 10 dan membandingkan hasilnya berdasarkan MSE dan PSNR. Sampel citra 6 menunjukkan hasil terbaik dengan nilai MSE = 0,010607 dan PSNR = 19,744[19]. Penelitian ini mencari tahu lebih dalam dari dampak penggunaan Image Enhancement Contrast Stretching dalam klasifikasi CT-Scan tumor ginjal menggunakan Deep Learning dilakukan melalui serangkaian tahapan untuk memastikan hasil yang optimal.

Tahapan-tahapan penelitian seperti yang terlihat pada gambar berikut.



Gambar 1. Metode Penelitian

Gambar 1 menggambarkan tentang tahapan dalam melakukan penelitian. Tahapan meliputi pengumpulan data, *preprocessing*, implementasi *deep learning* dan evaluasi. Tahapan awal adalah pengumpulan data untuk penelitian yang di dapat dari website kaggle. Selanjutnya data di *preprocessing* dengan dilakukan *image enhancement* dan *resize*. Setelah itu, data yang sudah di proses akan digunakan untuk melatih model menggunakan *deep learning*. Model akan dievaluasi menggunakan metode *confusion matrix*.

A. *Pengumpulan Data*

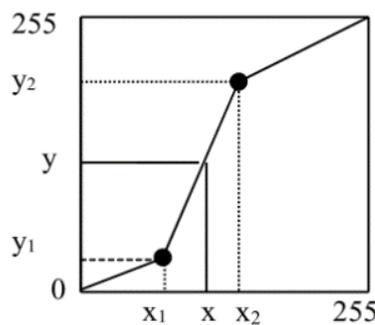
Pada tahap ini dilakukan pengumpulan data ct-scan ginjal yang akan dijadikan inputan. *Dataset* yang digunakan adalah *dataset CT-Scan* ginjal yang didapat dari *website Kaggle* yang berjumlah 12.446 gambar yang terdiri dari kista 3.709, normal 5.077, batu 1.377, dan tumor 2.283. Penelitian ini hanya menggunakan data pengujian yang telah didapatkan adalah normal dan tumor.

B. *Preprocessing*

Tahap berikutnya adalah melakukan *preprocessing* pada data CT-scan ginjal. Data citra CT-scan akan melalui proses peningkatan citra (*image enhancement*) dengan menggunakan metode *contrast stretching* dan penyesuaian ukuran (*resize*). Seluruh langkah *preprocessing* ini dilaksanakan dengan menggunakan bahasa pemrograman Python.

1. *Image Enhancement Contrast Stretching*

Contrast stretching merupakan teknik yang digunakan untuk mendapatkan citra baru dengan kontras yang lebih baik daripada kontras dari citra asalnya.



Gambar 2. Transformasi Contrast Stretching

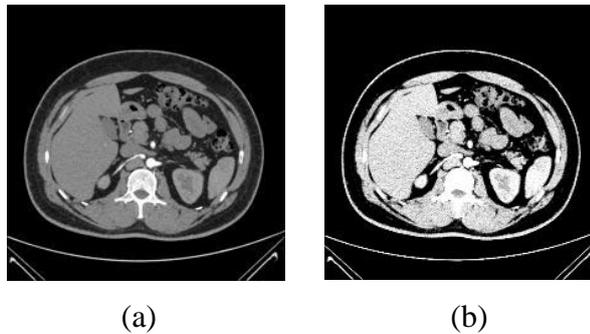
Pada Gambar 2, *x* merupakan nilai piksel dari citra sebelum diproses, sedangkan *y* adalah nilai piksel dari citra setelah diproses. Titik-titik tersebut akan menentukan bentuk fungsi transformasi dan distribusi tingkat keabuan dari citra yang dihasilkan. Pada *contrast stretching* dapat diasumsikan bahwa citra memiliki range gray level dari 0 sampai 255. Titik (*x1, y1*) dan (*x2, y2*) akan memengaruhi bentuk fungsi transformasi dan distribusi tingkat keabuan pada citra yang dihasilkan. Jika *x1 = x2* dan *y1 = y2* sehingga transformasi akan berbentuk garis lurus, yang berarti tidak ada perubahan tingkat keabuan pada citra yang dihasilkan. Untuk menghitung nilai hasil transformasi, dapat menggunakan fungsi berikut:

$$0 \leq x < x_1, \text{ maka } y = y_1 * \left(\frac{x}{x_1}\right) \tag{1}$$

$$x_1 \leq x < x_2, \text{ maka } y = y_1 + \frac{(y_2 - y_1) * (x - x_1)}{(x_2 - x_1)} \tag{2}$$

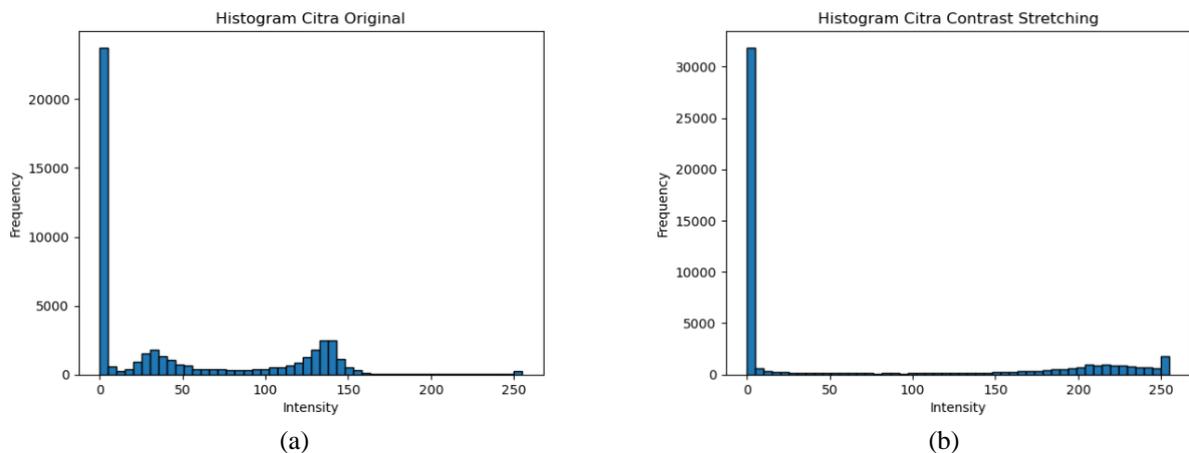
$$x_2 \leq x \leq 255, \text{ maka } y = y_2 + \frac{(255 - y_2) * (x - x_2)}{(255 - x_2)} \tag{3}$$

Dengan : $x_1, x_2, y_1, y_2 =$ sembarang nilai, besarnya dari 0 sampai 255. Untuk menghindari hasil negatif dari proses transformasi, sebaiknya nilai $x_1 \leq x_2$ dan nilai $y_1 \leq y_2$, sehingga diperoleh nilai pixel yang baru diantara 0 sampai 255.



Gambar 3. (a) Citra Original (b) Citra *Contrast Stretching*

Gambar 3 (a) adalah gambar citra sebelum dilakukan image enhancement contrast stretching. Pada gambar tersebut bisa terlihat bahwa citra tampak gelap. Sedangkan hasil peningkatan kontras menggunakan image enhancement contrast stretching dapat dilihat pada Gambar 3 (b). Citra tampak lebih tajam dibandingkan dengan citra original.



Gambar 4. (a) Histogram Citra Original (b) Histogram Citra *Contrast Stretching*

Gambar 4 (a) adalah gambar histogram citra original. Pada gambar histogram tersebut bisa terlihat bahwa sebaran intensitas piksel hanya ada di rentang 0-160. Sedangkan hasil dari histogram setelah dilakukan *image enhancement contrast stretching* sebaran intensitasnya diperluas menjadi 0-255.

2. *Resize*

Setelah dataset dilakukan proses contrast stretching, dataset akan diubah ukurannya menjadi 224x224 piksel untuk memudahkan dalam memperoleh nilai ekstraksi selama proses ekstraksi fitur. Resolusi ini dipilih karena pada model arsitektur *efficientnet-b0* ketetapan resolusinya adalah 224x224 pixel.

C. *Deep Learning*

Setelah dataset dilakukan contrast stretching dan resize, selanjutnya data dibagi menjadi data latih, data validasi, dan data uji. Proses pembagian dataset dibagi dengan rasio 80% dari

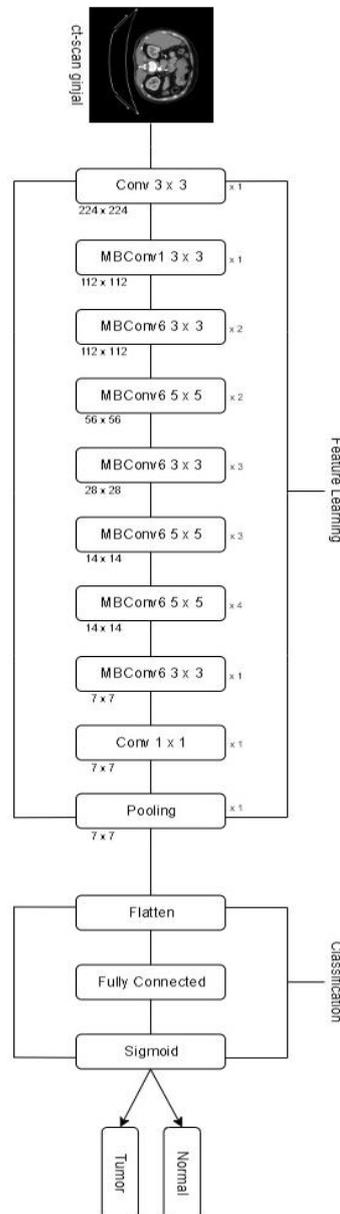
total dataset digunakan untuk pelatihan model, 10% untuk validasi, dan 10% untuk pengujian. Sehingga masing-masing kelas terdiri dari 1824 data latih, 228 data validasi, 228 data uji.

TABEL I
PEMBAGIAN DATA

Kelas	Dataset			Dataset Contrast Stretching		
	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. *EfficientNet-B0*

EfficientNet-B0 merupakan salah satu arsitektur model yang sudah dilatih sebelumnya dan terbukti memberikan akurasi tinggi dengan meningkatkan efektivitas model melalui optimalisasi parameter. [10] Berikut adalah gambar ilustrasi dari arsitektur EfficientNet-B0.



Gambar 5. Arsitektur EfficientNet-B0

D. Hyperparameter Optimization

Optimisasi hyperparameter merupakan proses untuk mencari kombinasi optimal dari hyperparameter dengan tujuan untuk mengoptimalkan fungsi kerugian (loss function) pada jaringan neural. [11] Tensorflow adalah salah satu framework open-source milik Google untuk mengembangkan dan melatih model yang ada di deep learning. Tensorflow menyediakan opsi untuk melakukan pengoptimalan model cnn yang ingin di bangun antara lain ada *Adadelta, Adafactor, Adagrad, Adam, Radam, AdamW, Adamax, Ftrl, Lion, Nadam, Optimizer, RMSprop, SGD (Gradient Descent)*. Penelitian ini akan menggunakan hyperparameter optimization *RAdam* dan *Adamax*. *Optimizer Adamax* merupakan salah satu optimazer yang menghasilkan performa lebih baik dibanding optimizer Adam, N-Adam, dan SGD[20]. Optimizer lain yang menghasilkan performa lebih baik yaitu RAdam dibandingkan optimizer Adam[11].

E. Evaluasi

Tahap evaluasi melibatkan pemeriksaan akurasi model yang telah dibuat. Evaluasi akurasi dilakukan menggunakan matriks klasifikasi seperti confusion matrix, yang mengevaluasi akurasi, presisi, recall, dan F1-Score dari model tersebut.

1. Akurasi

Ini digunakan untuk menghitung persentase kelas prediksi yang benar dibandingkan dengan jumlah total sampel yang dievaluasi.

$$Akurasi = \frac{TP+FP}{TP+FP+TP+FN} \tag{1}$$

2. Presisi

Digunakan untuk menghitung pola positif yang diprediksi dengan benar oleh semua pola prediksi di kelas positif.

$$Presisi = \frac{TP}{TP+FP} \tag{2}$$

3. Recall

Ini digunakan untuk menghitung proporsi pola positif yang berhasil diklasifikasikan dengan benar dari keseluruhan pola positif yang sebenarnya ada.

$$Recall = \frac{TP}{TP+FN} \tag{3}$$

4. F1-Score

Menghitung rata-rata harmonik antara tingkat *recall* dan presisi.

$$F1 - Score = 2 \times \frac{Precision \times recall}{Precision + recall} \tag{4}$$

III. HASIL DAN PEMBAHASAN

A. Pelatihan Model

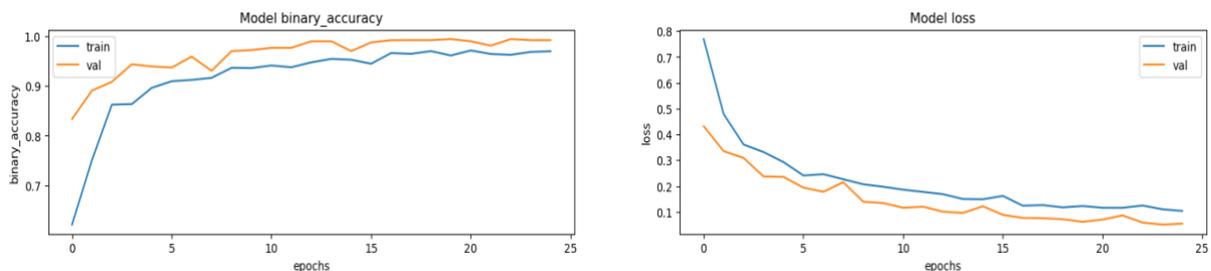
Ekspirimen dilakukan menggunakan Jupyter Notebook di Visual Studio Code dengan menggunakan bahasa pemrograman Python. Selain itu, eksperimen ini memanfaatkan beberapa pustaka seperti NumPy, Matplotlib, TensorFlow, dan lainnya untuk mendukung pembuatan model dalam penelitian ini.

TABEL II
PELATIHAN MODEL MENGGUNAKAN DATASET ORIGINAL DAN CONTRAST STRETCHING

No.	Rasio Dataset	Dataset	Optimizer	LearningRate	Training Binary Accuracy	Validation Binary Accuracy
1	80:20	Original	Adamax	0.01	0.9690	0.9912
2	80:20	Original	Adamax	0.001	0.9416	0.9605
3	80:20	Original	Adamax	0.0001	0.8254	0.8640
4	80:20	Original	RAdam	0.01	0.9575	0.9803
5	80:20	Original	RAdam	0.001	0.9693	0.9890
6	80:20	Original	RAdam	0.0001	0.8769	0.9057

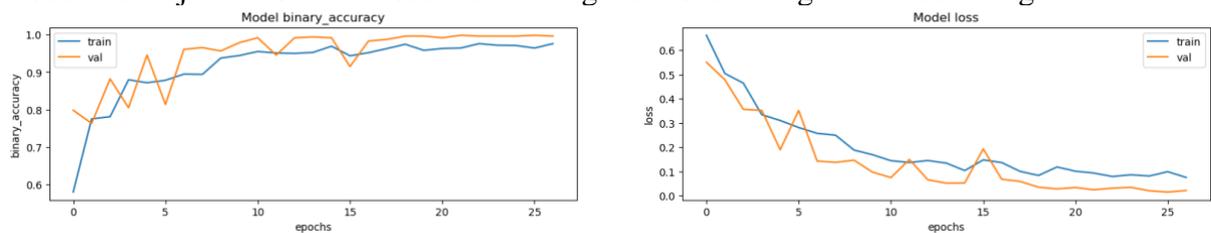
No.	Rasio Dataset	Dataset	Optimizer	LearningRate	Training Binary Accuracy	Validation Binary Accuracy
7	80:20	Contrast Stretching	Adamax	0.01	0.9843	0.9963
8	80:20	Contrast Stretching	Adamax	0.001	0.9678	0.9744
9	80:20	Contrast Stretching	Adamax	0.0001	0.8903	0.9049
10	80:20	Contrast Stretching	RAdam	0.01	0.9781	0.9978
11	80:20	Contrast Stretching	RAdam	0.001	0.9804	0.9956
12	80:20	Contrast Stretching	RAdam	0.0001	0.9121	0.9291

Tabel II menunjukkan bahwa pelatihan model dilakukan pada 2 jenis dataset yaitu dataset original dan dataset contrast stretching. Pelatihan dijalankan dengan berbagai variasi hyperparameter dan dilakukan hingga 50 epoch. Hasil pelatihan dengan validation binary accuracy tertinggi untuk dataset original terdapat pada eksperimen ke-1, sedangkan pada jenis dataset contrast stretching validation binary accuracy tertinggi terdapat pada eksperimen ke-10.



Gambar 6. Grafik Pelatihan Dataset Original

Gambar 6 menunjukkan grafik pelatihan untuk dataset original pada percobaan ke-1 menggunakan optimizer Adamax dengan learning rate 0.01. Garis biru pada grafik tersebut adalah training binary accuracy dengan nilai 0.9690 dan garis orange pada grafik tersebut adalah validation binary accuracy dengan nilai 0.9912. Berdasarkan grafik dari hasil pelatihan model menunjukkan bahwa model tidak mengalami overfitting atau underfitting.



Gambar 7. Grafik Pelatihan Dataset Contrast Stretching

Gambar 7 menunjukkan grafik pelatihan untuk dataset contrast stretching pada percobaan ke-10 menggunakan optimizer RAdam dengan learning rate 0.01. Garis biru pada grafik tersebut adalah training binary accuracy dengan nilai 0.9781 dan garis orange pada grafik tersebut adalah validation binary accuracy dengan nilai 0.9978. Berdasarkan grafik dari hasil pelatihan model menunjukkan bahwa model tidak mengalami overfitting atau underfitting.

B. Pengujian Model

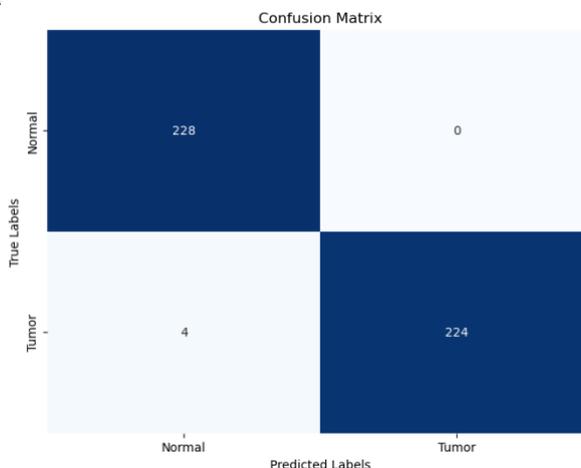
Setelah menyelesaikan tahap pelatihan model dengan menggunakan dataset pelatihan dan validasi, langkah berikutnya adalah melakukan pengujian model menggunakan dataset pengujian. Pengujian dilakukan terhadap semua model yang telah dilatih dengan dataset asli dan dengan penerapan contrast stretching. Evaluasi kinerja model dilakukan dengan

menganalisis confusion matrix yang mencakup nilai akurasi (accuracy), presisi (precision), recall, dan nilai F1-score, serta hasil prediksi untuk setiap kelas.

TABEL III
HASIL PENGUJIAN MENGGUNAKAN DATASET ORIGINAL DAN CONTRAST STRETCHING

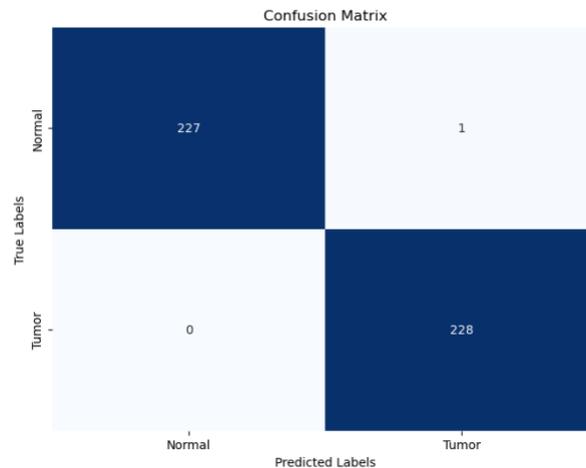
No.	Rasio Dataset	Dataset	Optimizer	Learning Rate	Accuracy	Precision	Recall	F1-Score
1	80:20	Original	Adamax	0.01	99.12	98.28	100.00	99.13
2	80:20	Original	Adamax	0.001	96.71	96.10	97.37	96.73
3	80:20	Original	Adamax	0.0001	87.28	85.42	89.91	87.61
4	80:20	Original	RAdam	0.01	98.68	97.44	100.00	98.70
5	80:20	Original	RAdam	0.001	98.90	97.85	100.00	98.92
6	80:20	Original	RAdam	0.0001	92.11	90.34	94.30	92.27
7	80:20	Contrast Stretching	Adamax	0.01	99.92	99.85	100.00	99.92
8	80:20	Contrast Stretching	Adamax	0.001	98.24	98.67	97.81	98.24
9	80:20	Contrast Stretching	Adamax	0.0001	90.27	90.10	90.52	90.29
10	80:20	Contrast Stretching	RAdam	0.01	99.78	99.56	100.00	99.78
11	80:20	Contrast Stretching	RAdam	0.001	99.56	99.13	100.00	99.56
12	80:20	Contrast Stretching	RAdam	0.0001	92.25	91.64	92.98	92.31

Tabel III menunjukkan hasil pengujian yang menggunakan data uji yang belum pernah digunakan sebelumnya. Hasil pengujian menunjukkan bahwa pada dataset original, akurasi tertinggi tercapai pada percobaan ke-1, sedangkan pada dataset contrast stretching, akurasi tertinggi tercapai pada percobaan ke-7.



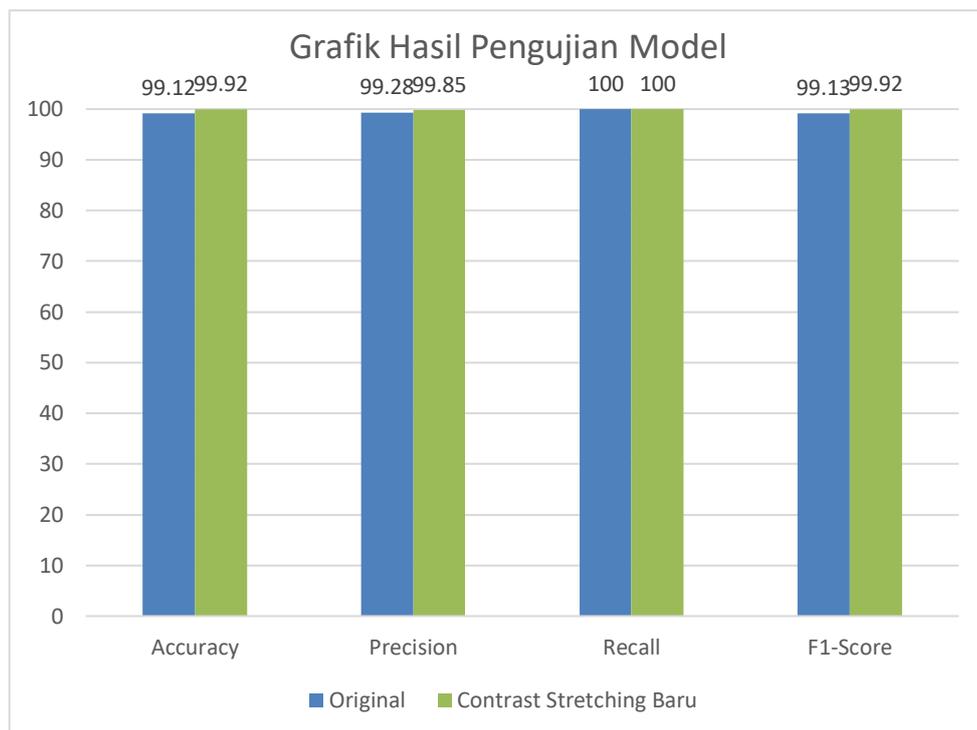
Gambar 8. Confusion Matrix Dataset Original

Gambar 8 merupakan Confusion Matrix dari percobaan ke-1 model dataset original dengan label prediksi (Predicted Labels) dan label asli (True Labels). Dari visualisasi confusion matrix tersebut, model hanya membuat 4 kesalahan prediksi di mana data Tumor diprediksi sebagai Normal, dan tidak ada kesalahan prediksi untuk data Normal yang diprediksi sebagai Tumor. Semua data Normal (228) diprediksi sebagai Normal, dan 224 dari 228 data Tumor diprediksi sebagai Tumor. Hasil pengujian ini menunjukkan bahwa model mencapai akurasi 99.12%, precision 100%, recall 98.25%, dan f1-score 99.12%



Gambar 9. Confusion Matrix Dataset Contrast Stretching

Gambar 9 merupakan Confusion Matrix dari percobaan ke-7 model dataset contrast stretching dengan label prediksi (Predicted Labels) dan label asli (True Labels). Dari visualisasi confusion matrix tersebut, model hanya membuat 1 kesalahan prediksi di mana data Normal diprediksi sebagai Tumor, dan tidak ada kesalahan prediksi untuk data Tumor yang diprediksi sebagai Normal. Semua data Tumor (228) diprediksi sebagai Tumor, dan 227 dari 228 data Normal diprediksi sebagai Normal. Hasil pengujian ini menunjukkan bahwa model mencapai akurasi 99.92%, precision 99.85%, recall 100%, dan f1-score 99.92%



Gambar 10. Grafik Perbandingan Hasil Pengujian Model

Gambar 10 menampilkan grafik perbandingan dari hasil pengujian model data original dan data contrast stretching. Dari grafik tersebut menunjukkan bahwa model dengan dataset contrast stretching yang ditandai grafik berwarna hijau memiliki performa tertinggi yaitu, accuracy 99,92%, precision 99,85%, recall 100% dan f1-score 99,92%. Sedangkan model dengan dataset original yang ditandai grafik berwarna biru menghasilkan performa sedikit lebih rendah yaitu, accuracy 99.12%, precision 98.28%, recall 100%, f1-score 99.13%.

IV. KESIMPULAN

Penelitian ini bertujuan untuk mengetahui pengaruh penggunaan teknik Image Enhancement Contrast Stretching untuk klasifikasi tumor ginjal menggunakan deep learning. Dataset yang digunakan diperoleh dari website kaggle dengan kelas Normal dan Tumor. Selanjutnya dataset dilakukan Contrast Stretching dan Resize menjadi 224x224 pixel. Resolusi 224x224 dipilih karena pada penelitian ini model dibangun menggunakan arsitektur EfficientNet-B0. Dataset dibagi dengan rasio 80% dari total dataset digunakan untuk pelatihan model, 10% untuk validasi, dan 10% untuk pengujian. Sehingga masing-masing kelas terdiri dari 1824 data latih, 228 data validasi, 228 data uji. Dari hasil pelatihan dan pengujian model menunjukkan bahwa penggunaan teknik Image Enhancement Contrast Stretching menggunakan optimizer Adamax learning rate sebesar 0.01 memiliki performa tertinggi yaitu dengan akurasi 99,92%, presisi 99,85%, recall 100%, dan F1-score 99,92%. Sedangkan hasil untuk dataset original menggunakan optimizer Adamax learning rate 0.01 didapatkan performa tertinggi yaitu dengan accuracy 99.12%, precision 98.28%, recall 100%, f1-score 99.13%. Dapat disimpulkan bahwa penggunaan teknik Image Enhancement Contrast Stretching untuk klasifikasi tumor ginjal menggunakan deep learning dapat meningkatkan performa model karena hasil citra yang dihasilkan lebih baik dari citra original. Untuk penelitian selanjutnya, disarankan menggunakan teknik Contrast Stretching terhadap citra RGB dan menggunakan arsitektur lain seperti VGG16.

REFERENSI

- [1] J. Kesehatan Saintika Meditory, N. Syuryani, E. arman, G. Eka Putri, and S. Syedza Saintika, "Perbedaan Kadar Ureum Sebelum Dan Sesudah Hemodialisa Pada Penderita Gagal Ginjal Kronik Difference In Ureum Levels Before And After Hemodialysis At Ahmad Mokhtar Bukit Tinggi Hospital In 2021", [Online]. Available: <https://jurnal.syedzasaintika.ac.id>
- [2] F. Aulia *et al.*, "Implementasi Algoritma Convolutional Neural Network Untuk Mendeteksi Penyakit Ginjal," 2022. [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- [3] A. Sylvia Lestari and H. Harun, "Pemeriksaan Penunjang Dalam Mendiagnosis Tumor Ginjal," 2019.
- [4] A. S. Lestari, M. A. Munir, and W. Suarsana, "Laporan Kasus : Pemeriksaan Penunjang Dalam Mendiagnosis Tumor Ginjal," 2021.
- [5] W. Angga, W. Kusuma, and A. Kusumadewi, "Penerapan Metode Contrast Stretching, Histogram Equalization Dan Adaptive Histogram Equalization Untuk Meningkatkan Kualitas Citra Medis Mri," *Jurnal SIMETRIS*, vol. 11, no. 1, 2020.
- [6] T. Suparwati and J. Kamp Walker Kampus Baru Waena Jayapura, "Perbaikan Citra Menggunakan Metode Contrast Stretching."
- [7] D. D. Ruikar, K. C. Santosh, and R. S. Hegadi, "Contrast Stretching-Based Unwanted Artifacts Removal from CT Images," in *Communications in Computer and Information Science*, Springer Verlag, 2019, pp. 3–14. doi: 10.1007/978-981-13-9184-2_1.
- [8] Windy Deftia Mertiana, Tri Arief Sardjono, and Nada Fitriyatul Hikmah, "Peningkatan Kontras Citra Mamografi Digital dengan Menggunakan CLAHE dan Contrast Stretching," 2020.
- [9] D. Gunawan and H. Setiawan, "Convolutional Neural Network dalam Analisis Citra Medis," 2022.
- [10] G. Ay, A. Durdu, and B. S. Nesimioğlu, "Accuracy Comparison of CNN Networks on GTSRB Dataset," *Journal of Artificial Intelligence and Data Science (JAIDA)*, vol. 2, no. 2, pp. 63–68, 2022, [Online]. Available: <https://dergipark.org.tr/pub/jaida>

- [11] H. Almirza, S. Sanjaya, L. Handayani, and F. Syafria, “Klasifikasi Daging Sapi dan Daging Babi Menggunakan Convolutional Neural Network EfficientNet-B0 dengan Augmentasi Citra,” *Media Online*, vol. 3, no. 6, pp. 1013–1021, 2023, doi: 10.30865/klik.v3i6.910.
- [12] Z. Gong and L. Kan, “Segmentation and classification of renal tumors based on convolutional neural network,” *J Radiat Res Appl Sci*, vol. 14, no. 1, pp. 412–422, Dec. 2021, doi: 10.1080/16878507.2021.1984150.
- [13] D. Alzu’bi *et al.*, “Kidney Tumor Detection and Classification Based on Deep Learning Approaches: A New Dataset in CT Scans,” *J Healthc Eng*, vol. 2022, pp. 1–22, Oct. 2022, doi: 10.1155/2022/3861161.
- [14] C. L. Choudhury, B. K. Mishra, C. Mahanty, and R. Kumar, “Brain Tumor Detection and Classification Using Convolutional Neural Network and Deep Neural Network,” 2020.
- [15] Y. Finsensia Riti and S. S. Tandjung, “Klasifikasi Covid-19 Pada Citra CT Scans Paru-Paru Menggunakan Metode Convolution Neural Network,” 2022.
- [16] S. Maqsood, R. Damaševičius, and R. Maskeliūnas, “Multi-Modal Brain Tumor Detection Using Deep Neural Network and Multiclass SVM,” *Medicina (Lithuania)*, vol. 58, no. 8, Aug. 2022, doi: 10.3390/medicina58081090.
- [17] Nur Nafi’iyah and Endang Setyati, “Lung X-Ray Image Enhancement to Identify Pneumonia with CNN,” *2021 3rd East Indonesia Conference on Computer and Information Technology (EIConCIT)*, 2021, doi: 10.1109/E.
- [18] D. Abdillah Salafy, F. Yanto, S. Agustian, and F. Insani, “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] Tio Ramadhan, Febriyanti A. Wara, and Imelda Dua Reja, “Analisis Perbaikan Citra Digital Menggunakan Metode Contrast Streching”.
- [20] I. Maulana, N. Khairunisa, R. Mufidah Informatika, U. H. Singaperbangsa Karawang Jl Ronggo Waluyo, T. Timur, and J. Barat, “Deteksi Bentuk Wajah Menggunakan Convolutional Neural Network (CNN),” 2023.