

EVALUASI TEKNIK AUGMENTASI DATA UNTUK KLASIFIKASI TUMOR OTAK MENGGUNAKAN CNN PADA CITRA MRI

(PERFORMANCE EVALUATION OF CNN MODELS WITH VARIOUS DATA AUGMENTATION TECHNIQUES ON MRI IMAGES FOR BRAIN TUMOR CLASSIFICATION)

Dede Husen¹⁾

¹⁾Fakultas Ilmu Komputer, Universitas Kuningan

Kuningan, Jawa Barat

e-mail: dede.husen@uniku.ac.id¹⁾

ABSTRAK

Klasifikasi tumor otak pada citra Magnetic Resonance Imaging (MRI) merupakan tantangan besar dalam bidang radiologi dan teknologi medis. Untuk meningkatkan akurasi diagnosis, metode Convolutional Neural Network (CNN) telah menunjukkan potensi besar. Namun, keterbatasan dataset pelatihan yang memadai menjadi kendala utama dalam pengembangan model yang efektif. Penelitian ini bertujuan untuk mengevaluasi kinerja model CNN dengan menerapkan berbagai teknik augmentasi data untuk klasifikasi tumor otak serta mengidentifikasi teknik augmentasi data yang paling efektif. Teknik augmentasi yang diuji meliputi penskalaan citra, rotasi acak, flip vertikal dan horizontal, kecerahan acak, serta kombinasi dari berbagai teknik augmentasi tersebut. Hasil penelitian menunjukkan bahwa teknik augmentasi penskalaan dan flip vertikal serta horizontal memberikan rata-rata akurasi tertinggi sebesar 92,97%, dengan akurasi maksimal mencapai 100% pada epoch ke-20 menggunakan teknik flip vertikal dan horizontal. Dengan demikian, diharapkan hasil penelitian ini dapat dimanfaatkan oleh peneliti lain dalam memilih teknik augmentasi yang tepat untuk citra MRI.

Kata Kunci: Klasifikasi Tumor Otak, Magnetic Resonance Imaging, Convolutional Neural Network, Aug-mentasi Data

ABSTRACT

Brain tumor classification on Magnetic Resonance Imaging (MRI) scans poses a significant challenge in the fields of radiology and medical technology. To enhance diagnostic accuracy, Convolutional Neural Network (CNN) methods have shown great potential. However, the limitation of having an adequate training dataset remains a major obstacle in developing effective models. This study aims to evaluate the performance of CNN models by applying various data augmentation techniques for brain tumor classification and identifying the most effective augmentation techniques. The augmentation techniques tested include image scaling, random rotation, vertical and horizontal flipping, random brightness adjustments, and combinations of these various techniques. The results indicate that the scaling and vertical and horizontal flipping techniques yield the highest average accuracy of 92.97%, with a maximum accuracy of 100% achieved at the 20th epoch using the vertical and horizontal flipping technique. Thus, it is hoped that the findings of this study can be utilized by other researchers in selecting appropriate augmentation techniques for MRI images.

Keywords: Brain Tumor Classification, Magnetic Resonance Imaging, Convolutional Neural Network, Data Augmentation

I. PENDAHULUAN

Klasifikasi tumor otak menggunakan citra MRI merupakan salah satu tantangan besar dalam bidang radiologi dan teknologi medis. *Magnetic Resonance Imaging (MRI)* adalah teknik pencitraan medis non-invasif yang menggunakan medan magnet dan gelombang radio untuk menghasilkan gambar detail dari organ dan jaringan dalam tubuh[1]. tumor adalah kondisi yang serius dan memerlukan diagnosis yang cepat serta akurat untuk menentukan tindakan medis yang tepat. Saat ini, penggunaan teknologi kecerdasan buatan khususnya metode

Convolutional Neural Network (CNN), telah menunjukkan potensi besar dalam meningkatkan akurasi diagnosis melalui analisis citra medis.

Namun, salah satu kendala utama dalam pengembangan model CNN yang efektif adalah keterbatasan jumlah data pelatihan yang tersedia. Dalam praktiknya, citra MRI yang berkualitas tinggi dan diberi label dengan baik sering kali terbatas jumlahnya. Untuk mengatasi masalah ini, teknik augmentasi data telah diterapkan untuk memperluas set data pelatihan secara signifikan. Augmentasi data mencakup berbagai teknik seperti rotasi, penskalaan, translasi, dan refleksi citra yang bertujuan untuk meningkatkan

keragaman data tanpa mengubah label sebenarnya.

Penelitian sebelumnya yang telah dilakukan oleh alsaf dkk [2] telah menunjukkan bahwa penggunaan teknik augmentasi data dapat secara substansial meningkatkan kinerja model CNN dengan arsitektur VGG-16 hingga mencapai akurasi 96% dengan teknik augmentasi yang digunakan adalah teknik *flipping* (membalik gambar), *rotation* (rotasi), dan *translation* (translasi). Kemudian pada penelitian yang sejenis yang dilakukan oleh liyananta M dkk. [3] tentang klasifikasi tumor otak menggunakan CNN dengan arsitektur ResNet 50 telah berhasil mendapatkan akurasi terbaik sebesar 96%.

Dalam penelitian ini, kami fokus pada evaluasi kinerja model CNN dengan menerapkan berbagai teknik augmentasi data pada citra MRI untuk klasifikasi tumor otak. Tujuan utama dari penelitian ini adalah untuk mengidentifikasi teknik augmentasi data yang paling efektif dalam meningkatkan akurasi klasifikasi model CNN. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode diagnosis yang lebih canggih dan akurat dalam bidang radiologi, serta memperkaya literatur ilmiah mengenai aplikasi teknik augmentasi data dalam klasifikasi citra medis.

II. STUDI PUSTAKA

Penelitian yang dilakukan oleh winarto dkk [4] pada tahun 2022 tentang klasifikasi tumor otak menggunakan metode CNN dengan arsitektur MobileNetV2 pada *dataset* public yang terdiri dari 3167 citra MRI yang dibagi kedalam 4 kelas citra yaitu *Glioma Tumor*, *Meningioma Tumor*, *Tumor Pituitari* dan citra tanpa tumor telah berhasil membuat sebuah model yang dapat mengklasifikasikan jenis tumor tersebut dengan akurasi sebesar 88.64% dengan nilai *loss* 0.3434. dari penelitian tersebut masih memungkinkan jika akurasi ditingkatkan lebih tinggi

Penelitian yang lainnya yang dilakukan oleh [5] tentang klasifikasi citra daging babi dan daging sapi menggunakan CNN dengan arsitektur ResNet-50 dengan 2 jenis skema data uji yaitu *dataset* asli dengan *dataset* augmentasi berhasil mencapai rata-rata akurasi 87.64% dan berhasil menghindari *overfitting* berkat aumentasi data tersebut.

Studi yang sama pernah dilakukan oleh Milica dkk pada tahun 2020 [6] dalam mengklasifikasikan jenis tumor otak dimana *dataset* yang diajukan berjumlah 3064 citra MRI. Pada penelitian ini telah dilakukan teknik augmentasi data pada masing-masing citra, teknik augmentasi yang diterapkan pada masing-masing citra adalah teknik rotasi 90°, dan *vertical flip* sebanyak 3 kali pengulangan, hasil dari augmentasi tersebut menghasilkan 9192 citra baru. Metode yang digunakan pada penelitian ini adalah metode CNN, dimana akurasi yang didapatkan adalah sebesar 96.56%.

Studi kasus lain yang dilakukan oleh Nabila zulfa dkk. [7] pada klasifikasi citra penyakit daun padi menggunakan CNN dengan arsitektur NASNetLarge menunjukkan peningkatan akurasi yang cukup signifikan dimana hasil klasifikasi dengan menggunakan *dataset* tanpa augmentasi adalah sebesar 94.31% kemudian setelah diterapkan teknik augmentasi data *horizontal flip*, *vertical flip* dan color augmentation Tingkat akurasi bertambah dari menjadi 98.70%

Dalam penelitian citra medis lainnya seperti yang dilakukan oleh [8] dalam artikelnya menjelaskan bahwa penggunaan citra medis dengan deep learning CNN telah dilakukan oleh para peneliti sebelumnya. Hasil dari penelitian ini menunjukkan penggunaan *deep learning* cukup signifikan dan menjadi tren tersendiri saat ini.

Penelitian serupa juga pernah dilakukan oleh [9] dalam mengklasifikasikan citra tumor otak dengan *dataset* berjumlah 2875 citra yang dibagi kedalam 2 jenis tumor yaitu glioma dan meningioma dimana nilai akurasi tertinggi mencapai 99.7% dan F1-Score mencapai 99.6%. Arsitektur CNN yang digunakan dalam eksperimen ini adalah arsitektur Efficientnet-B3 dan menyimpulkan pada model ini *learning rate* tinggi mempengaruhi hasil akurasi modelnya dimana tidak ada proses augmentasi data pada model ini.

Studi yang lain juga pernah dilakukan oleh. [10] pada klasifikasi penyakit mata menggunakan metode CNN dengan arsitektur alexnet dengan *dataset* asli sebanyak 610 data yang dibagi kedalam 4 kelas yaitu mata normal, katarak, glaucoma dan retina disease. Hasil dari penelitian ini tingkat akurasinya adalah 98.37% akan tetapi jika dilihat grafik akurasi validasinya terjadi *overfitting* itu dibuktikan dengan tingginya bias pada grafik tersebut.

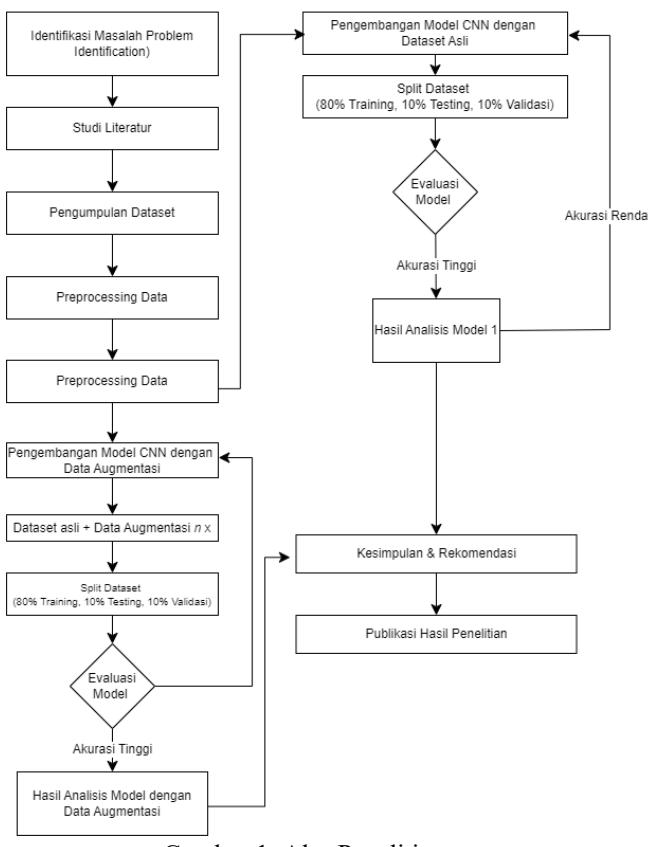
Dalam kasus penelitian citra medis lain seperti yang dilakukan oleh [11] menunjukkan bahwa

peran data augmentasi dapat secara signifikan memberikan hasil terbaik dalam meningkatkan akurasi sebuah model. Pada penelitian ini berfokus kepada peningkatan kualitas dari *dataset* yang mempunyai kualitas terbatas menjadi *dataset* yang berkualitas tinggi dengan menggunakan teknik augmentasi *noise, scale, rotate and flip*.

III. METODE PENELITIAN

A. Model dan Desain Penelitian

Pada penelitian ini penulis menggunakan model penelitian eksperimental [12], penulis mengontrol perlakuan spesifik atau *treatment* pada objek penelitian dimana telah dilakukan berbagai macam uji coba *training dataset* citra tumor otak mulai dari pengujian *dataset* asli dengan *dataset* artifisial dengan menggunakan berbagai macam teknik augmentasi, kemudian dilakukan juga berbagai uji coba pengujian dari masing-masing teknik augmentasi hingga mencoba mengubah variabel terkait dalam proses pembuatan model klasifikasinya. Untuk lebih jelasnya berikut desain penelitian (*research design*) yang telah dilakukan:



Gambar 1. Alur Penelitian

Langkah pertama yang penulis lakukan adalah melakukan identifikasi masalah yang akan menjadi objek penelitian, dalam kasus ini penulis mengidentifikasi efektivitas teknik augmentasi

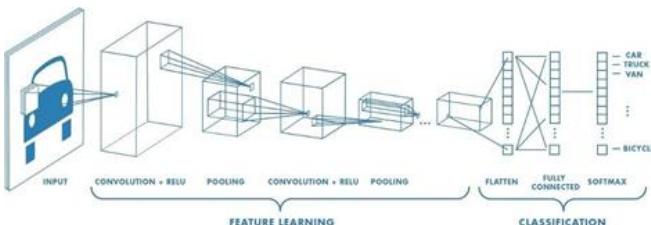
data yang tepat dalam proses klasifikasi citra hasil MRI tumor otak manusia, selanjutnya penulis mengumpulkan studi-studi literatur yang telah ada dan mencari hal yang belum banyak di teliti oleh para akademisi ataupun praktisi dalam hal ini tidak banyak yang menyenggung seputar metode augmentasi data yang tepat, selanjutnya penulis melakukan pencarian dataset melalui sumber-sumber yang ada seperti pada situs kaggle.com. Proses selanjutnya adalah proses eksperimental terhadap dataset yang ada menggunakan metode *Convolutional Neural Network (CNN)* dan melakukan serangkaian uji coba dengan berbagai teknik baik dengan dataset asli maupun dengan melakukan berbagai teknik augmentasi yang memungkinkan sampai pada hasil yang akurat. Datasate tersebut penulis bagi ke dalam 80% dataset *training*, 10% dataset *testing* dan 10% *dataset* validasi. Proses eksperimen tersebut terus berulang hingga penulis mendapatkan nilai akurasi tertinggi dan menyimpulkan sebuah hipotesis yang akan dituliskan dibagian hasil dan pembahasan. Langkah terakhir adalah mempublikasikan hasil dari penelitian kedalam sebuah jurnal ilmiah.

B. Metode Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu metode yang umum diterapkan dalam analisis data citra, dengan inspirasi yang diambil dari mekanisme kerja visual korteks primata. Arsitektur CNN terdiri dari beberapa komponen kunci yang berperan penting dalam pemrosesan citra. Komponen-komponen utama dari CNN terdiri dari lapisan konvolusi (*convolutional layer*), lapisan masukan (*input layer*), lapisan keluaran (*output layer*), serta sejumlah lapisan tersembunyi (*hidden layers*) yang terdiri dari lapisan *pooling* (*pooling layer*), lapisan normalisasi (*normalization layer*), lapisan *Rectified Linear Unit (ReLU layer)*, dan lapisan *fully connected layer*, dan lapisan *loss layer*. Setiap lapisan memiliki fungsi spesifik yang berkontribusi terhadap kinerja keseluruhan jaringan saraf tiruan dalam mengenali dan mengklasifikasikan fitur-fitur dari citra yang diberikan. CNN telah terbukti sangat efektif dalam berbagai aplikasi, mulai dari pengenalan objek hingga segmentasi gambar, berkat kemampuannya dalam menangkap pola dan detail dari data visual secara efisien.[13]

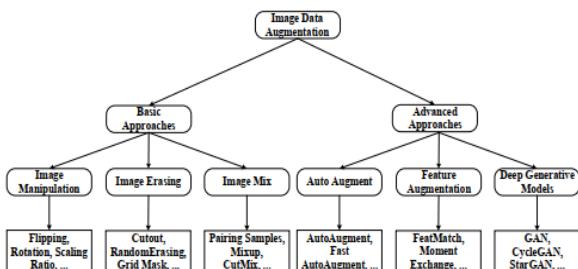
Pada penelitian ini Jenis arsitektur yang digunakan adalah jenis klasik atau sederhana.

Arsitektur ini dipilih untuk menguji dan mengevaluasi pengaruh akurasi antara *dataset* asli dengan *dataset* artifisial atau data yang telah mengalami augmentasi. Berikut gambar arsitektur CNN klasik:



Gambar 2 Arsitektur CNN

C. Augmentasi Data



Gambar 3 Taksonomi Teknik Data Augmentasi

Augmentasi data adalah salah satu cara untuk meningkatkan jumlah data secara signifikan dengan berbagai tekniknya bahkan dalam beberapa tahun terakhir dalam sebuah artikel *literatur review* ini menyebutkan dalam kurun 5 tahun terakhir terjadi peningkatan yang signifikan artinya semakin banyak paneliti menggunakan teknik augmentasi data citra medis [14]. Dalam model *deep learning* teknik augmentasi data sering digunakan untuk menambah jumlah keragaman *dataset* dengan menghasilkan data sintetis. Secara umum teknik augmentasi data dibagi kedalam dua jenis yaitu metode augmentasi dasar (*basic approaches*) yang meliputi teknik memanipulasi gambar seperti *flipping*, *rotation*, *scaling ratio*, *noise injection*, *color space*, *contras*, *sharpening*, *translation* dan *cropping*. Dua teknik dasar augmentasi lainnya adalah teknik penghapusan sebagian gambar (*image erasing*) dan teknik pencampuran gambar (*image mixing*). Kemudian jenis yang kedua adalah teknik augmentasi lanjutan (*advanced approaches*) dibagi kedalam tiga bagian yaitu teknik *auto augment*, *feature augmentation* dan *deep generative model*[15]. Berikut taksonomi dari metode augmentasi data.

Dalam penelitian ini penulis mencoba membandingkan teknik augmentasi yang tepat pada kasus klasifikasi citra MRI tumor otak ini, dengan demikian diharapkan akan menemukan kombinasi terbaik dari berbagai teknik augmentasi yang ada.

D. Confusion Matrix

Untuk menguji kinerja dari model klasifikasi yang kita bangun maka peran *confusion matrix* ini cukup penting dimana dengan menggunakan kita akan dapat mengevaluasi model kita terlebih label yang diuji lebih dari dua jenis label atau bisa kita sebut klasifikasi multilabel[16]. Bentuk dari *confusion matrix* ini adalah sebuah tabel yang mencatat prediksi benar yang bernilai benar (true positif), prediksi benar bernilai negative (true negative), prediksi salah dengan value benar (false positif) dan prediksi salah bernilai salah (false negative)[17]. Berikut tabel dari *confusion matrix*

Tabel 1 Confusion Matrix

		Actual Values	
		Positive	Negative
Predicted Values	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

Dari tabel *confusion matrix* tersebut kita dapat menghitung metrik lainnya seperti akurasi (*accuracy*), presisi (*precision*), sensitivitas (*recall*) dan *F1 score*. Berikut detail dari matrix tersebut

1) Akurasi (*accuracy*)

Metrik akurasi digunakan values dengan benar, artinya metrik ini menghitung jumlah prediksi yang benar (*True Positive* dan *True Negative*) yang dibagi dengan jumlah keseluruhan data testing. Berikut rumusnya:

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100\% \quad (1)$$

2) Presisi (*Precision*)

Presisi adalah metrik evaluasi yang mengukur seberapa akurat model dalam

membuat prediksi benar untuk kelas positif dari total prediksi positif yang dilakukan. Ini menunjukkan persentase prediksi positif yang benar (*True Positive*) di antara semua prediksi positif, membantu menilai kemampuan model dalam mengidentifikasi kelas positif tanpa salah mengklasifikasikan kelas negatif sebagai positif. Berikut rumus untuk menghitung presisi:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (2)$$

3) Sensitivitas (*Recall*)

Metrik evaluasi lainnya adalah sensitivitas atau *recall* yaitu metrik yang menggambarkan seberapa banyak sebuah model memprediksi kelas positif (*True positive*) dengan benar. Untuk menghitungnya kita dapat membagi jumlah prediksi yang benar (*True positive*) dengan total jumlah prediksi benar ditambah dengan jumlah prediksi salah (*False Negative*). Berikut rumus lebih jelasnya :

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (3)$$

4) *F1 Score*

F1 Score merupakan metrik evaluasi yang mencerminkan keseimbangan antara presisi (*precision*) dan sensitivitas (*recall*). *F1 Score* menunjukkan seberapa baik model kita dalam mengklasifikasikan hasil prediksi positif dan negatif dengan akurat. Berikut rumusnya:

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

IV. HASIL DAN PEMBAHASAN

Dalam proses *training* modelnya penulis menggunakan spesifikasi laptop dengan processor Intel core i5-1135G7 Gen 11th dengan clock speed @2.40GHz (8 CPUs), RAM 16 GB, VGA Inten Iris XE. Dengan spesifikasi tersebut penulis dapat menyimpulkan proses *training* model sepenuhnya dilakukan oleh melalui CPU. Adapun akan lebih baik jika menggunakan tambahan VGA tambahan seperti Nvidia GTx atau RTX series untuk mempercepat proses *training* data.

A. Dataset

Penelitian ini menggunakan *dataset* citra *Magnetic Resonance Imaging (MRI)* yang diperoleh dari repositori *dataset* publik Kaggle[18]. Dataset ini merupakan gabungan dari beberapa *dataset* tumor otak yang tersedia secara publik di Kaggle dan terbagi ke dalam empat kelas, yaitu glioma, meningioma, notumor, dan pituitary

Tabel 2. Dataset Tumor Otak

No.	Jenis Tumor	Jumlah Data
1	Glioma	1.621
2	Meningioma	1.645
3	Notumor	2.000
4	Pituitary	1.757
	Total	7.023

Dalam proses pembagian *dataset*, penulis membaginya ke dalam tiga kelompok data, yaitu data *training* sebanyak 80%, data *testing* sebanyak 10%, dan data *validation* sebanyak 10%. Pendekatan ini memastikan bahwa model yang dikembangkan dapat dilatih dengan cukup data untuk mengidentifikasi pola dan fitur spesifik dari setiap jenis tumor, serta diuji dan divalidasi untuk mengukur kinerjanya secara akurat. Pembagian *dataset* yang proporsional ini adalah langkah penting untuk menghindari *overfitting* dan memastikan generalisasi model terhadap data baru. Lebih jelasnya kita bisa melihat sebaran *dataset* yang di atur dalam proses *training* modelnya dibawah ini:

Tabel 3 Sebaran Dataset

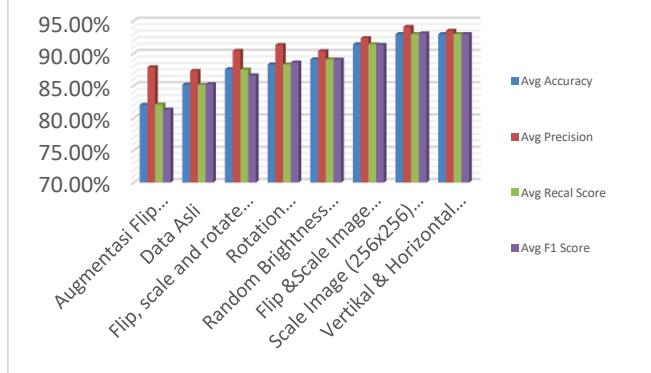
Data	Persentase	Jumlah
Training	80%	5.617
Testing	10%	703
Validation	10%	703
Total		7.023

B. Pengaruh Data Augmentasi

Augmentasi data adalah teknik yang digunakan dalam *machine learning* untuk memperbanyak data dari *dataset* asli yang berguna untuk meningkatkan akurasi dan menghindari *overfitting* pada model yang kita bangun [19]

Dalam proses eksperimennya penulis menggunakan metode CNN dengan beberapa skema model data uji yang beragam, mulai dari pengujian dengan data tumor otak asli kemudian melakukan pengujian dengan menggunakan

berbagai teknik augmentasi data baik augmentasi dengan metode geometris seperti teknik *vertical* dan *horizontal flip*, *scale image* dan random rotation. Selain itu teknik lain juga diterapkan pada model ini diantaranya adalah teknik random brightness hingga teknik kombinasi dari berbagai macam teknik augmentasi yang disebutkan tadi. Total dari experiment ini adalah 32 kali percobaan yang dibagi kedalam 8 jenis pengujian *dataset*, 1 diantaranya menggunakan *dataset* asli dan 7 diantaranya menggunakan *dataset* dengan teknik augmentasi dan masing-masing pengujian ditentukan nilai *epoch*-nya yaitu 5,10,15,20 *epoch*. Secara keseluruhan berikut hasil dari rata-rata metrik uji dengan menggunakan confusion metrik:



Gambar 4 Perbandingan Metrik Akurasi, presisi, *recall* dan *F1 Score*

Berdasarkan grafik diatas hasil analisis terhadap kinerja model dengan beberapa teknik augmentasi data untuk meningkatkan performa klasifikasi. terlihat bahwa teknik augmentasi memiliki pengaruh yang signifikan terhadap peningkatan metrik evaluasi.

Eksperimen 1

Pengujian pertama model CNN dengan Dataset asli menunjukkan rata-rata akurasi sebesar 85,16% dengan *precision* 87,29%, *recall* 85,11%, dan *F1 score* 85,23% . lebih jelasnya tabel dibawah dapat menunjukkan hasil dari *experiment* yang telah dilakukan terhadap *dataset* asli :

Tabel 4 Hasil Eksperimen 1

Epoch	accuracy (%)	Precision (%)	Recall (%)	<i>F1</i> Score (%)	Time
5	78.12	78.59	78.12	77.41	0:47:06
10	84.38	84.75	84.18	84.18	5:12:37
15	87.50	92.05	87.50	88.06	6:57:39
20	90.62	93.75	90.62	91.26	1:28:57
Avg.	85.16	87.29	85.11	85.23	

Dari tabel diatas kita dapat melihat pengaruh banyaknya *epoch*[20] juga mempengaruhi metrik evaluasi serta jumlah waktu yang dipakai untuk *training* modelnya.

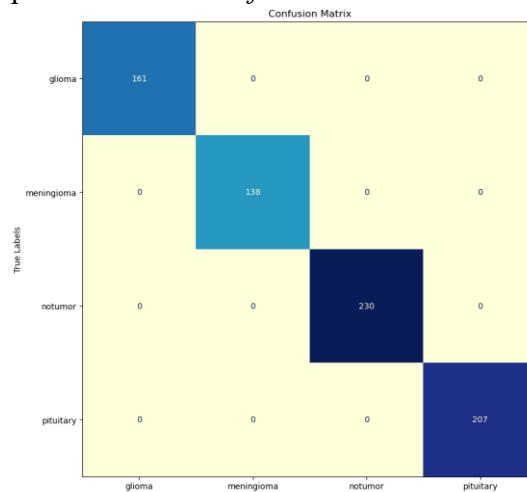
Eksperimen 2

Eksperimen kedua ini penulis menerapkan teknik augmentasi berupa *flip vertikal* dan *horizontal*, terjadi peningkatan performa dengan akurasi rata-rata menjadi 88,28%, *precision* 90,33%, *recall* 88,23%, dan *F1 score* 88,50%. Seperti pada eksperimen sebelumnya nilai *epoch* mempunyai pengaruh pada nilai metrik evalusinya. Berikut detail hasil dari pengujian dengan metode augmentasi *vertical* and *horizontal flip*.

Tabel 5 Hasil Eksperimen 2

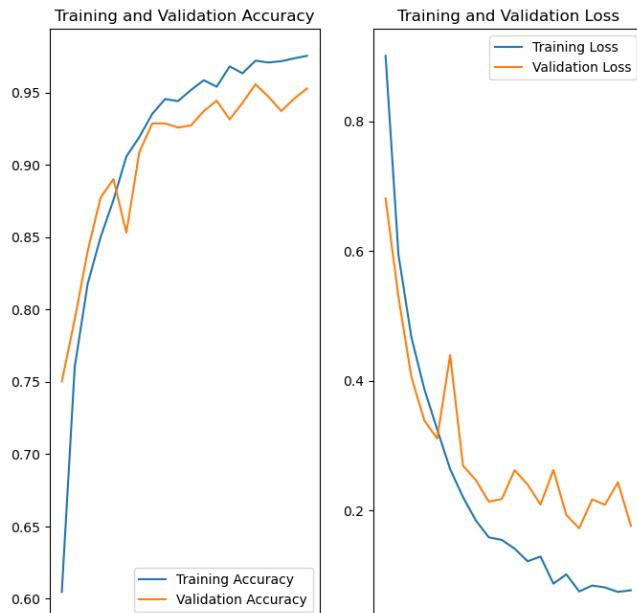
Epoch	accuracy (%)	Precision (%)	Recall (%)	<i>F1</i> Score (%)	Time
5	90.62	90.76	90.62	90.49	0:39:48
10	96.88	97.32	96.88	96.90	1:09:59
15	84.38	85.90	84.38	84.50	1:53:44
20	100.00	100.00	100.00	100.00	1:24:15
Avg.	88.28	90.33	88.23	88.50	

Dari tabel diatas kita dapat melihat pada *epoch* ke-20 tingkat akurasi, presisi, *recall* dan *F1 Score* ada pada tingkat tertinggi yaitu 100%, hal ini dapat dilihat dari *confusion matrix* dibawah ini:



Gambar 5. Confusion Matrix dengan Data Agumentasi flip dengan nilai Epoch 20

Dari gambar *confusion matrix* tersebut kita dapat melihat dengan jelas bahwa tingkat akurasinya adalah tepat semua. Untuk lebih jelasnya berikut hasil *training* dan validasi dari model dengan teknik augmentasi *vertical* and *horizontal flip*:



Gambar 6 accuracy dan loss graphic

Dari grafik sebelah kiri tersebut kita dapat hasil *training* dan validasi akurasi dengan jumlah *epoch* 20 tersebut, dimana itu menunjukkan peningkatan yang signifikan dan cendrung stabil diatas 95%. Pada grafik sebelah kanan adalah *training* dan *loss* validation dimana nilai dari *loss* berada pada kisaran 0.2 dan *training loss* berada pada kisaran 0.1 kebawah yang artinya, meskipun sekilas terlihat adanya sedikit *overfitting* dari model tersebut bias di toleir karna hasil dari prediksi pada *confusion matrix* sebelumnya dimana seluruhnya tepat sesuai dengan gambar-gambar aktualnya.

Eksperimen 3

Selanjutnya, pada augmentasi dengan teknik rotasi 20 derajat memberikan hasil yang lebih baik dengan akurasi rata-rata 91,41% *precision* 93,47% *recall* 91,41%, dan F1 score 91,68%. Teknik augmentasi skala gambar ke dari ukuran 512x512 ke ukuran 256x256 juga menunjukkan peningkatan yang signifikan, menghasilkan akurasi rata-rata 90,63%, *precision* 91,93%, *recall* 90,63%, dan F1 score 90,79%. Berikut penulis sajikan dalam bentuk tabel:

Tabel 6 Hasil Eksperimen 3

Epoch	accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	Time
5	90.62	93.44	90.62	90.71	0:47:06
10	84.38	85.24	84.38	84.32	0:48:36
15	93.75	94.27	93.75	93.82	1:10:15
20	84.38	92.19	84.38	85.51	1:37:37
Avg.	91.41	93.47	91.41	91.68	

Dari tabel diatas kita dapat melihat nilai accuracy dan metrik yang lainnya cendrung fluktuatif, akan tetapi rata-rata dari gabungan setiap metriknya secara keseluruhan cukup baik, dan seperti pada experiment sebelumnya durasi pengujian akan meningkat sesuai dengan jumlah *epoch*.

Eksperimen 4

Teknik Augmentasi tunggal terakhir yang diterapkan adalah teknik augmentasi random brightness, teknik ini memberikan performa terbaik dengan akurasi rata-rata mencapai 92,97%, *precision* 93,50%, *recall* 92,97%, dan F1 score 92,97%. Berikut detail dari hasil pengujian ini:

Tabel 7 Hasil Eksperimen 4

Epoch	accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	Time
5	87.50	87.43	87.50	87.26	0:34:07
10	90.62	91.32	90.62	90.35	1:13:22
15	90.62	90.55	90.62	90.43	1:34:11
20	87.50	92.05	87.50	88.08	2:37:04
Avg.	92.97	93.50	92.97	92.97	

Jika dilihat dari Tabel tersebut terjadi peningkatan dari *epoch* ke-5 ke *epoch* 15, akan tetapi di *epoch* ke-20 terjadi penurunan sekitar 3%, akan tetapi jika dirata-ratakan teknik augmentasi ini mempunyai nilai metrik evaluasi tertinggi.

Eksperimen 5

Pada eksperimen ini penulis melakukan teknik augmentasi kombinasi, dimana teknik kombinasi pertama adalah dengan menggabungkan teknik augmentasi *flip* dan *scale image*. Rata-rata hasil dari pengujian ini adalah sebagai berikut:

Tabel 8 Hasil Eksperimen 5

Epoch	accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	Time
5	84.38	84.66	84.38	84.13	0:37:01
10	96.88	97.22	96.88	96.86	01:32:28
15	90.62	92.72	90.62	90.54	1:23:38
20	93.75	94.79	93.75	93.69	1:33:52
Avg.	92.97	94.17	92.97	93.03	

Dari hasil tersebut kita dapat melihat rata-rata hasil pengujian mengalami peningkatan yang cukup signifikan, nilai akurasi tertinggi berada pada *epoch* ke-10 yaitu 96.88%, nilai tersebut diatas rata-rata dari keseluruhan metrik pengujian dimana nilai rata-rata akurasi keseluruhan adalah 92.97%, presisi 94.17%, *recall* 92.97% dan nilai F1 Score adalah 93.03%.

Eksperimen 6

Pada eksperimen ini penulis melakukan pengujian model dengan *dataset* yang diterapkan teknik augmentation gabungan yaitu, teknik *flip*, random rotation dan scale *images*. Hasil dari pengujian model ini didapatkan nilai akurasi tertinggi 96.88% pada *epoch* ke-15. Lebih detailnya berikut hasil pengujinya:

Tabel 9 Hasil Eksperimen 6

Epoch	accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	Time
5	65.62	74.61	65.62	64.00	0:52:55
10	93.75	94.27	93.75	93.82	1:12:58
15	96.88	97.66	96.88	97.02	1:25:23
20	93.95	95.00	93.75	98.81	1:42:44
Avg.	89.85	91.15	89.85	89.88	

Dari tabel tersebut kita dapat melihat rata-rata akurasi berada di angkata 89.85%, presisi 91.15%, *recall* 89.85% dan *F1 Score* 89.88. dari hasil tersebut kita dapat menyimpulkan bahwa teknik augmentation gabungan belum tentu memberikan efek yang baik terhadap tingkat akurasi ataupun metrik lainnya dari sebuah *dataset* uji.

Eksperimen 7

Dalam eksperimen ini penulis melakukan pengujian dengan menggabungkan seluruh teknik augmentation yang dilakukan sebelumnya yaitu penggabungan teknik *flip*, *scale*, *random rotation* dan *random brightness* menghasilkan nilai akurasi tertinggi sebesar 90.62% pada *epoch* ke-15 akan tetapi terjadi penurunan akurasi pada *epoch* ke-20. Berikut tabel lengkapnya:

Tabel 10 Hasil Eksperimen 7

Epoch	accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	Time
5	71.88%	87.57%	71.88%	70.25%	0:28:39
10	87.50%	89.17%	87.50%	86.49%	0:54:24
15	90.62%	90.39%	90.62%	90.34%	1:28:08
20	78.12%	84.30%	78.30%	78.12%	1:46:08
Avg.	82.03%	87.86%	82.08%	81.30%	

Dari tabel diatas kita dapat melihat terjadi peningkatan secara signifikan dari *epoch* ke-5 dengan tingkat akurasi 71.88% hingga *epoch* ke-20 dengan akurasi 90.62% akan tetapi turun menjadi 78.12% pada *epoch* ke-20. Nilai rata-rata keseluruhan dari skema pengujian teknik augmentation gabungan ini tidak jauh lebih baik dibanding yang lain dimana rata-rata akurasi adalah 82.03%, presisi 87.86%, *recall* 82.08% dan *F1 Score* 81.30%.

V. KESIMPULAN DAN SARAN

Kesimpulan

Dari hasil analisis dan evaluasi model diatas, dapat disimpulkan bahwa augmentasi data pada citra MRI tumor otak terutama augmentasi *vertical horizontal flip* dan Augmentasi *Scale Images* dengan rata-rata akurasi sebesar 92.97%, pada augmentasi *vertical horizontal* bahkan mencapai nilai maksimal 100% pada *epoch* ke-20 yang secara signifikan meningkatkan kinerja model klasifikasi dibandingkan dengan data asli. Oleh karena itu, teknik augmentation data sangat direkomendasikan untuk meningkatkan performa model dalam tugas-tugas klasifikasi citra khususnya citra MRI. Akan tetapi teknik yang digunakan sebaiknya disesuaikan dengan karakteristik citra yang akan dijadikan *dataset*, pada kenyataannya tidak semua jenis teknik augmentation cocok dengan *dataset* uji, perlu eksperimen lebih lanjut dalam prosesnya baik dalam arsitektur modelnya ataupun metode yang digunakan.

Saran

Dalam proses penelitian ini ada beberapa rekomendasi dalam meningkatkan metrik evaluasi atau kinerja sebuah model klasifikasi citra, dalam menggunakan teknik data augmentation sebaiknya perlu dipertimbangkan jenis teknik augmentation yang akan diterapkan dan disesuaikan dengan peruntukannya, hal ini dapat dilihat dari tujuan akhir pemodelan ini adalah untuk *mobile device* sebaiknya menggunakan teknik augmentation data yang mampu mengubah arah pandang atau *scanning image*. Penggunaan teknik augmentation yang terlalu banyak juga tidak menjamin model akan menjadi lebih baik. Untuk mengatasi hal tersebut harus dilakukan berbagai macam percobaan sebelum proses *deployment* ke dalam sebuah aplikasi.

DAFTAR PUSTAKA

- [1] Cleveland Clinic, “MRI (Magnetic Resonance Imaging).” Accessed: Jul. 28, 2024. [Online]. Available: <https://my.clevelandclinic.org/health/diagnostics/4876-magnetic-resonance-imaging-mri>
- [2] H. Alsaif *et al.*, “A Novel Data Augmentation-Based Brain Tumor Detection Using Convolutional Neural Network,” *Applied Sciences (Switzerland)*, vol. 12, no. 8, Apr. 2022, doi: 10.3390/app12083773.
- [3] M. S. Liyananta, M. Shata, N. Latifah, F. Bimantoro, and T. Informatika, “Program Studi Teknik Informatika,” 2024. [Online]. Available:

- <https://www.kaggle.com/datasets/thomasdubail/brain-tumors-256x256>
- [4] M. N. Winnarto, M. Mailasari, and A. Purnamawati, “KLASIFIKASI JENIS TUMOR OTAK MENGGUNAKAN ARSITEKTURE MOBILENET V2,” *Jurnal SIMETRIS*, vol. 13, no. 2, 2022.
- [5] S. Lasniari, J. Jasril, S. Sanjaya, F. Yanto, and M. Affandes, “Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra,” *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 3, no. 4, p. 450, Jun. 2022, doi: 10.30865/json.v3i4.4167.
- [6] M. M. Badža and M. C. Barjaktarović, “Classification of brain tumors from mri images using a convolutional neural network,” *Applied Sciences (Switzerland)*, vol. 10, no. 6, Mar. 2020, doi: 10.3390/app10061999.
- [7] A. Nabilla Zulfa, M. Irsyad, F. Yanto, and S. Sanjaya, “JURNAL MEDIA INFORMATIKA BUDIDARMA Optimasi Convolutional Neural Network NASNetLarge Menggunakan Augmentasi Data untuk Klasifikasi Citra Penyakit Daun Padi,” 2023, doi: 10.30865/mib.v7i2.6056.
- [8] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Analisis Citra Medis,” 2022.
- [9] R. Andre, B. Wahyu, and R. Purbaningtyas, “KLASIFIKASI TUMOR OTAK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR EFFICIENTNET-B3,” 2021. [Online]. Available: <https://jurnal.umj.ac.id/index.php/just-it/index>
- [10] F. Nurona Cahya *et al.*, “SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN).” [Online]. Available: <http://sistemasif.tik.unisi.ac.id>
- [11] Z. Fabian, R. Heckel, and M. Soltanolkotabi, “Data augmentation for deep learning based accelerated MRI reconstruction with limited data,” 2021. [Online]. Available: [https://github.com/MathFLDS/W. Budiharto and B. S. Abbas, *Panduan Riset & Publikasi Penelitian bagi Akademisi*, 1st ed. Yogyakarta: Andi Publisher, 2023.](https://github.com/MathFLDS/W. Budiharto and B. S. Abbas, Panduan Riset & Publikasi Penelitian bagi Akademisi, 1st ed. Yogyakarta: Andi Publisher, 2023.)
- [12] D. Bhatt *et al.*, “Cnn variants for computer vision: History, architecture, application, challenges and future scope,” Oct. 01, 2021, *MDPI*. doi: 10.3390/electronics10202470.
- [13] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway, and A. Haworth, “A review of medical image data augmentation techniques for deep learning applications,” Aug. 01, 2021, *John Wiley and Sons Inc.* doi: 10.1111/1754-9485.13261.
- [14] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, and F. Shen, “Image Data Augmentation for Deep Learning: A Survey,” Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.08610>
- [15] M. Heydarian, T. E. Doyle, and R. Samavi, “MLCM: Multi-Label Confusion Matrix,” *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [16] K. P. Shung, “accuracy, Precision, Recall or F1?” Accessed: Jul. 13, 2024. [Online]. Available: <https://towardsdatascience.com/accuracy-precision-recall-or-f1-331fb37c5cb9>
- [17] M. Nickparvar, “Brain Tumor MRI Dataset.” Accessed: Jul. 11, 2024. [Online]. Available: <https://www.kaggle.com/masoudnickparvar/brain-tumor-mri-dataset>
- [18] K. Maharana, S. Mondal, and B. Nemade, “A review: Data pre-processing and data augmentation techniques,” *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91–99, Jun. 2022, doi: 10.1016/j.gltip.2022.04.020.
- [19] T. Debnath, M. M. Reza, A. Rahman, A. Beheshti, S. S. Band, and H. Alinejad-Rokny, “Four-layer ConvNet to facial emotion recognition with minimal epochs and the significance of data diversity,” *Sci Rep*, vol. 12, no. 1, Dec. 2022, doi: 10.1038/s41598-022-11173-0.