

Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network

Dede Husen^{1)*}

¹⁾Universitas Kuningan

Jl. Cut Nyak Dhien No.36A, Cijoho, Kec. Kuningan, Kabupaten Kuningan, Jawa Barat, Indonesia

¹⁾dede.husen@uniku.ac.id

Article history:

Received 31 Juli 2024;
Revised 05 Agustus 2024;
Accepted 07 Agustus 2024;
Available online 20 Agustus 2024

Keywords:

Augmentasi Data
Convolutional Neural Network
Klasifikasi Citra
Magnetic Resonance Imaging
Tumor Otak

Abstract

Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi tumor otak menggunakan metode *Convolutional Neural Network (CNN)* pada citra *Magnetic Resonance Image (MRI)*. Berbagai eksperimen dilakukan menggunakan dataset asli dan dataset yang telah mengalami augmentasi untuk meningkatkan jumlah dan variasi data. *Dataset* yang digunakan adalah *dataset* publik dari Kaggle yang memiliki empat kelas tumor diantaranya, tumor kelas *glioma*, *meningioma*, *notumor*, dan kelas *pituitary*. Teknik augmentasi data yang diterapkan meliputi *flipping*, *scaling*, *random brightness*, *random rotation*, dan teknik augmentasi gabungan untuk memperkaya *dataset* pelatihan. Hasil penelitian menunjukkan bahwa augmentasi data dapat secara signifikan meningkatkan akurasi model CNN. Model terbaik diperoleh dengan teknik augmentasi gabungan *flipping* dan *scale*, menghasilkan rata-rata akurasi sebesar 92.97%. Penggunaan teknik augmentasi data tidak hanya meningkatkan akurasi tetapi juga mengurangi risiko *overfitting*, di mana model menjadi lebih generalis dan mampu mengenali pola pada data baru dengan lebih baik. Selain itu, parameter lain yang mempengaruhi akurasi adalah ukuran citra dan jumlah *epoch*. Penelitian ini memberikan kontribusi penting dalam bidang diagnosis medis dengan menyediakan model yang lebih akurat dan efisien untuk mendeteksi tumor otak. Dengan akurasi yang lebih tinggi dan risiko *overfitting* yang lebih rendah, model CNN yang dihasilkan diharapkan dapat digunakan sebagai alat bantu yang andal dalam diagnosis dan deteksi dini tumor otak, sehingga meningkatkan kualitas perawatan pasien dan hasil klinis.

I. PENDAHULUAN

Tumor otak merupakan salah satu penyakit mematikan di dunia yang dapat menyerang siapa saja [1], penyakit yang ditandai dengan pertumbuhan sel atau jaringan abnormal di otak ini secara medis dapat mengancam nyawa seseorang jika tidak ditandai dengan baik [2]. Salah satu cara mendiagnosisnya adalah menggunakan citra *Magnetic Resonance Imaging (MRI)*. MRI adalah salah satu teknik pengambilan citra medis dengan menggunakan medan magnet dan gelombang radio untuk menghasilkan gambar berbentuk 2 atau 3 dimensi secara detail dari organ dan jaringan tubuh manusia bagian dalam [3]. Tumor merupakan kondisi medis yang serius dan memerlukan diagnosis yang cepat serta akurat untuk menentukan intervensi medis yang tepat. Saat ini, penggunaan teknologi kecerdasan buatan, khususnya *Convolutional Neural Networks (CNN)*, telah menunjukkan peranan yang besar dalam meningkatkan akurasi diagnosis melalui analisis citra medis.

CNN dalam praktiknya telah diterapkan kedalam berbagai bidang seperti yang telah dilakukan oleh para peneliti lainnya, seperti yang dilakukan oleh Penelitian yang dilakukan oleh Winarto dkk [4] pada tahun 2022 mengenai klasifikasi tumor otak menggunakan metode CNN dengan arsitektur MobileNetV2 pada dataset publik yang terdiri dari 3167 citra MRI, yang dibagi menjadi 4 kelas yaitu Tumor Glioma, Tumor Meningioma, Tumor Pituitary, dan citra tanpa tumor, berhasil menghasilkan model yang mampu mengklasifikasikan jenis tumor tersebut dengan akurasi 88.64% dan nilai loss 0.3434. Penelitian ini menunjukkan bahwa masih ada potensi untuk meningkatkan akurasi lebih tinggi.

Metode lain pada kasus serupa juga pernah diteliti oleh Febrianti dkk. [5] menggunakan metode *Support Vector Machine (SVM)* pada citra MRI Tumor Otak dengan jumlah *dataset* citra sebanyak 100 buah. Dimana hasil akurasi yang didapatkan adalah sekitar 76%.

* Corresponding author

Penelitian lain juga telah dilakukan oleh [6] mengenai klasifikasi penyakit mata menggunakan metode CNN dengan arsitektur AlexNet. Penelitian ini menggunakan dataset asli yang terdiri dari 610 data, yang dibagi menjadi 4 kelas: mata normal, katarak, glaukoma, dan penyakit retina. Hasil penelitian menunjukkan tingkat akurasi sebesar 98.37%. Namun, grafik akurasi validasi menunjukkan adanya overfitting, yang ditandai dengan tingginya bias pada grafik tersebut.

II. TINJAUANUSTAKA

Dalam kurun waktu beberapa tahun terakhir metode CNN telah banyak digunakan untuk mengklasifikasi data berbentuk gambar, seperti yang dilakukan oleh Nabila Zulfa dkk.[7] mengenai klasifikasi citra penyakit daun padi menggunakan metode CNN dengan arsitektur NASNetLarge menunjukkan peningkatan akurasi yang signifikan. Pada awalnya, model CNN yang dilatih tanpa teknik augmentasi data mencapai akurasi sebesar 94.31%. Namun, setelah menerapkan teknik augmentasi data seperti horizontal flip, vertical flip, dan color augmentation, akurasi model meningkat menjadi 98.70%. Hasil ini menunjukkan bahwa teknik augmentasi data dapat secara efektif meningkatkan performa model dalam mengklasifikasikan penyakit daun padi, yang sangat bermanfaat untuk pertanian presisi dan pengelolaan tanaman yang lebih baik.

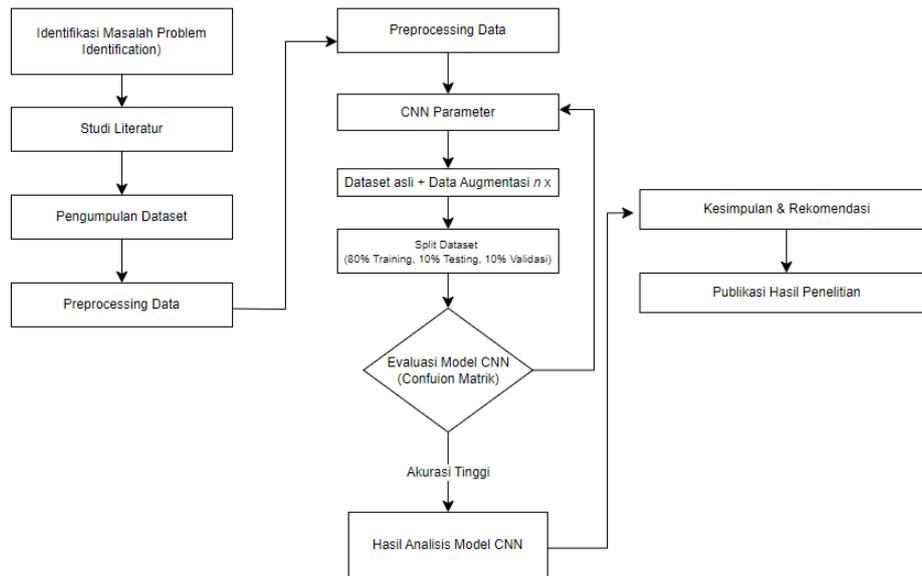
Studi yang lain pernah dilakukan oleh Badza M. dkk.[8] dalam mengklasifikasi jenis tumor otak dimana dataset yang diolah berjumlah 3064 citra MRI. Pada penelitian ini telah dilakukan teknik augmentasi data pada masing-masing citra, teknik augmentasi yang diterapkan pada masing-masing citra adalah teknik rotasi 900, 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%.

Dalam penelitian citra medis lainnya, seperti yang dijelaskan oleh Gunawan dkk[9] dalam artikelnya, penggunaan citra medis dengan *deep learning*, khususnya *Convolutional Neural Networks* (CNN), telah banyak dilakukan oleh para peneliti sebelumnya. Hasil dari penelitian tersebut menunjukkan bahwa penggunaan *deep learning* memiliki dampak yang signifikan dalam meningkatkan akurasi diagnosis dan analisis citra medis. Teknik ini tidak hanya mempercepat proses diagnosis, tetapi juga membantu dalam mendeteksi berbagai kondisi medis dengan lebih presisi. Penggunaan CNN dalam analisis citra medis telah menjadi tren yang berkembang pesat, dengan banyak penelitian yang menunjukkan efektivitasnya dalam berbagai aplikasi, mulai dari deteksi tumor hingga analisis struktur otak. Tren ini mencerminkan potensi besar *deep learning* dalam merevolusi bidang medis, memberikan alat yang lebih canggih dan efisien bagi para profesional kesehatan dalam menangani dan mendiagnosis penyakit.

III. METODE

A. Metode dan Desain penelitian

Dalam penelitian ini, penulis menggunakan model penelitian eksperimental, di mana penulis mengontrol perlakuan spesifik pada objek penelitian[10]. Penulis telah melakukan berbagai macam uji coba dengan *training dataset* citra tumor otak, mulai dari pengujian *dataset* asli hingga penambahan *dataset* artifisial yang dihasilkan menggunakan berbagai teknik augmentasi. Selain itu, berbagai uji coba dalam mengatur parameter model telah dilakukan, termasuk mengubah variabel terkait dalam proses pembuatan model klasifikasi. Untuk lebih jelasnya, berikut adalah desain penelitian yang telah dilakukan:



Berdasarkan gambar 1 desain alur penelitian di atas, penulis memulai dengan mengidentifikasi masalah, yaitu

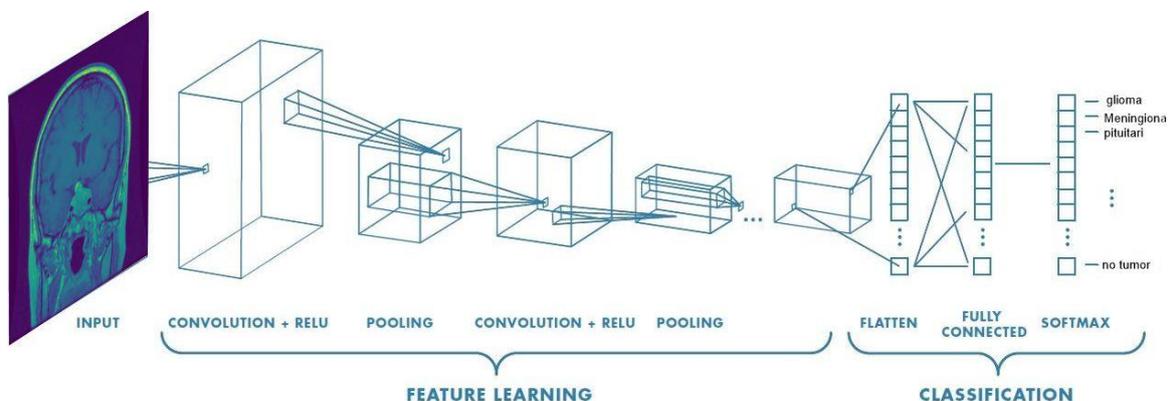
Gambar 1. Desain Alur Penelitian

klasifikasi tumor otak menggunakan metode CNN. Setelah itu, penulis melakukan studi literatur untuk mencari referensi penelitian terdahulu yang relevan. Tahap selanjutnya adalah pengumpulan dataset, yang diambil dari repositori dataset umum di situs Kaggle, dengan memilih dataset MRI otak terbaru. Penulis kemudian melakukan preprocessing data dan beragam eksperimen model CNN yang dikombinasikan dengan berbagai teknik augmentasi, serta menganalisis hasilnya satu per satu. Akhir dari penelitian ini adalah publikasi hasil penelitian pada jurnal yang bereputasi.

B. Metode Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu metode yang umum dit-erapkan dalam analisis data citra, dengan in-spirasi yang diambil dari mekanisme kerja vis-ual korteks primata. Arsitektur CNN terdiri dari beberapa komponen kunci yang berperan penting dalam pemrosesan citra. omponen-komponen utama dari CNN terdiri dari lapisan konvolusi (convolutional layer), lapisan ma-sukan (input layer), lapisan keluaran (output layer), serta sejumlah lapisan tersembunyi (hidden layers) yang terdiri dari lapisan pool-ing (pooling layer), lapisan normalisasi (nor-malization layer), lapisan Rectified Linear Unit (ReLU layer), dan lapisan fully connected lay-er, dan lapisan loss (loss layer). Setiap lapisan memiliki fungsi spesifik yang berkontribusi terhadap kinerja keseluruhan jaringan saraf tiruan dalam mengenali dan mengklasifikasi-kan 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.[11]

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:

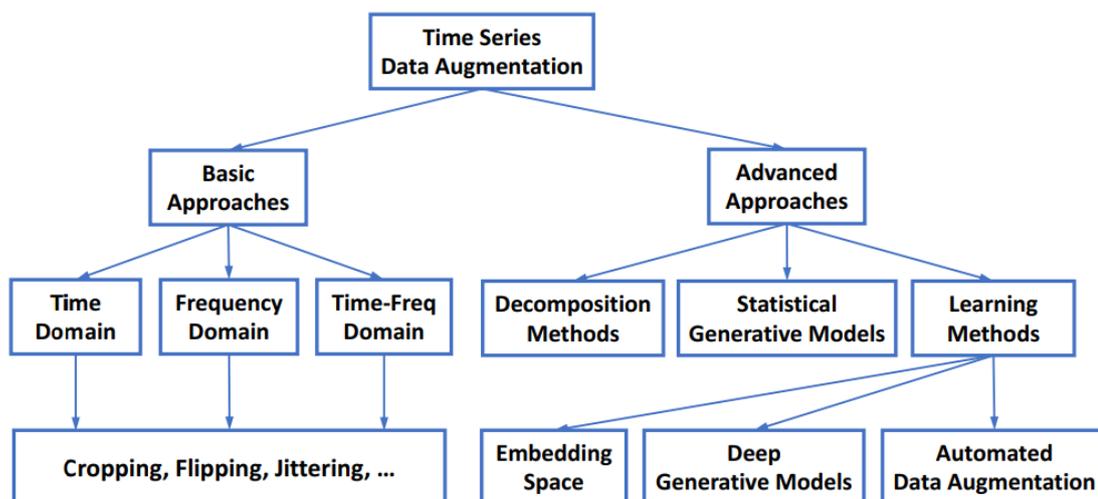


Gambar 2. Arsitektur CNN

Dari gambar tersebut kita dapat melihat desain dari arsitektur CNN dimana terdapat beberapa proses yang berjalan, Gambar tersebut menunjukkan alur metode *Convolutional Neural Network (CNN)* yang digunakan untuk klasifikasi tumor otak. Proses dimulai dengan *input* berupa gambar MRI otak. Gambar ini kemudian melewati beberapa lapisan konvolusi (*convolution*) yang diikuti oleh fungsi aktivasi *ReLU (Rectified Linear Unit)* untuk mengidentifikasi fitur-fitur penting. Setelah setiap lapisan konvolusi, terdapat lapisan *pooling* yang berfungsi untuk mengurangi dimensi data, sehingga mengurangi kompleksitas dan mempercepat proses komputasi. Proses ini berulang beberapa kali hingga mendapatkan fitur yang lebih abstrak. Setelah fitur-fitur penting diekstraksi, data kemudian dilewatkan ke lapisan *flatten* yang mengubah data dari bentuk dua dimensi menjadi satu dimensi. Selanjutnya, data ini dilewatkan ke lapisan *fully connected* yang menggabungkan semua fitur yang telah diekstraksi. Terakhir, lapisan *softmax* digunakan untuk mengklasifikasikan jenis tumor (*glioma, meningioma, pituitari, nnotumor*). Hasil klasifikasi ini didasarkan pada probabilitas tertinggi yang dihasilkan oleh lapisan *softmax*.

C. Augmentasi Data

Augmentasi data adalah salah satu cara untuk meningkatkan jumlah data secara signifikan dengan berbagai tekniknya bahkan dalam beberapa tahun terakhir dalam sebuah paper literatur review ini menyebutkan dalam kurun 5 tahun terakhir terjadi peningkatan yang signifikan artinya semakin banyak peneliti menggunakan teknik augmentasi data citra medis [12]. 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 aproaches*) yang meliputi teknik memanipulasi gambar seperti flipping, rotation, scaling ratio, noise injection, color space, kontras, 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[13]. Berikut taksonomi dari metode augmentasi data[14].



Gambar 3. Taksonomi Augmentasi Data

Dalam penelitian ini penulis mencoba menerakan 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 menggunakannya kita akan dapat mengevaluasi model kita terlebih label yang diuji lebih dari dua jenis label atau bisa kita sebut klasifikasi *multilabel*[15]. Bentuk dari *confusion matrix* ini adalah sebuah tabel yang mencatat prediksi benar yang bernilai benar (*true posiive*), prediksi benar bernilai *negative (true negative)*, prediksi salah dengan value benar (*false positive*) dan prediksi salah bernilai salah (*false negative*)[16]. Berikut tabel dari *confusion matrix*.

TABEL 1
CONFUSION MATRIX
Actual Values

	Positive	Negative
Positive		
Negative		

Positive	True Positive (TF)	False Negative (FP)
Negative	False Negative (FN)	True Negative (TN)

Dari tabel *confusion matrix* tersebut kita dapat menghitung metrik lainnya seperti akurasi (*accuracy*), presisi (*precision*), sensitifitas (*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 sensitifitas (*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

Dalam proses training model CNN, 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 sepe-nuhnya 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. Pengaruh Ukuran Citra

Pada pengujian ini penulis melakukan beberapa 2 eksperimen dalam dua skema, pertama penulis melakukan pengujian mode CNN dengan ukuran dataset citra asli yaitu 512x512 dan skema kedua yaitu dengan mengubah seluruh dataset citra menjadi ukuran 256x256. Berikut rata-rata hasil dari training modelnya:

TABEL 2
PERBANDINGAN HASIL DARI CONFUSION MATRIK CITRA ASLI DAN CITRA YANG DIPERKECIL

Ukuran Citra	Akurasi	Presisi	Recall	F1 Score	Loss Error	Waktu
512x512	85.16%	87.29%	85.11%	85.23%	0.27%	4:51:35
256x256	92.97%	93.50%	92.97%	92.97%	0.20%	1:16:57

Dari tabel diatas kita dapat melihat dari berbagai metrik evaluasi ukuran citra berpengaruh terhadap hasil *training* dataset yang diujikan, mulai dari akurasi, presisi, sensitivitas, *F1 Score* dan *loss error* nilainya cukup berpengaruh serta semakin besar ukuran citra waktu *training* akan lebih lama.

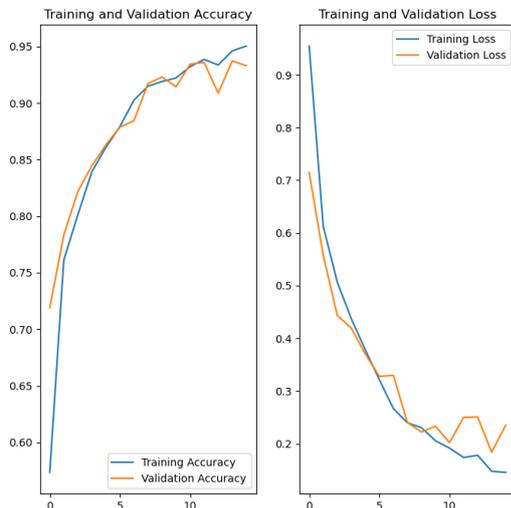
B. Pengaruh Data Augmentasi

Dalam proses training data dengan khususnya data citra sangat bergantung terhadap keragaman dataset, semakin banyak variasi data sebuah dataset citra akan semakin bagus, dan masalah yang sering ditemui dilapangan adalah ketersediaan dataset citra tersebut yang cenderung sedikit. Untuk mengatasi hal tersebut penulis menerapkan teknik augmentasi data untuk memperkaya dataset agar lebih beragam, selain dapat *meningkatkan* akurasi augmentasi data juga dapat mengurangi *overfitting* sebuah model. Dalam kasus ini penulis melakukan beberapa teknik augmentasi citra berikut hasilnya:

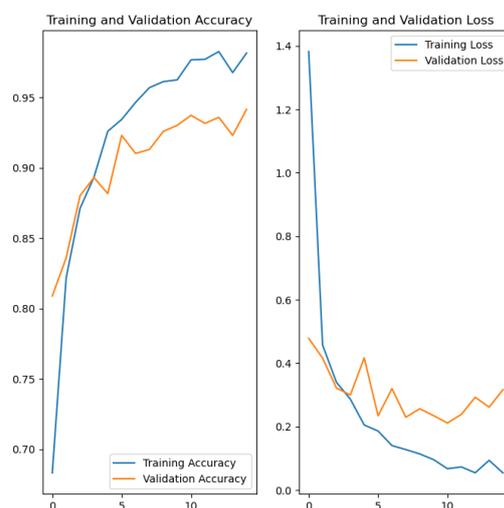
TABEL 3
PERBANDINGAN HASIL CONFUSION MATRIK DARI JENIS AUGMENTASI DATA

Jenis Dataset Augmentasi	Rata-rata					
	Akurasi	Presisi	Recall	F1 Score	Loss Error	Waktu
Original Data / No Augmentation	85.16%	87.29%	85.11%	85.23%	0.27%	4:51:35
Flip, scale and rotate	87.55%	90.39%	87.50%	86.61%	0.28%	1:18:30
Random Rotation 20°	88.28%	91.29%	88.28%	88.59%	0.24%	1:05:54
Random Brightness	89.06%	90.34%	89.06%	89.03%	0.31%	1:29:41
Flip & Scale Image	91.41%	92.35%	91.41%	91.31%	0.19%	1:11:30
Scale Image (256x256)	92.97%	94.10%	92.97%	93.09%	0.20%	2:06:42
Vertical & Horizontal Flip	92.97%	93.50%	92.97%	92.97%	0.20%	1:16:57

Dari hasil training augmentasi diatas, penulis dapat menyimpulkan bahwa teknik augmentasi data dapat mempengaruhi matrik akurasi seperti akurasi, presisi, sensitivitas (*Recall*), *F1 Score*, *loss error* dan total waktu training data. Pada penelitian ini kita dapat melihat perbandingan dari metrik evaluasi antara *dataset* asli dengan dataset yang diterapkan teknik augmentasi dapat meningkatkan akurasi secara signifikan. Augmentasi *Vertical & Horizontal Flip* memiliki nilai tertinggi pada kasus ini. Berikut grafik yang menunjukkan perbandingan hasil training dataset asli dengan dataset augmentasi terbaik:



Gambar 4
Grafik Training & Loss dengan Augmentasi Data



Gambar 5
Grafik Training & Loss Dataset Asli

Dari kedua grafik diatas kita dapat melihat bagaimana akurasi dan loss baik training maupun validasi sangat berbeda, di gambar 4 kita melihat hasil training dan validasi grafik cenderung stabil artinya model dapat bekerja dengan baik, akan tetapi pada gambar ke-5 kita dapat melihat ketidakstabilan training dan validasi akurasi cenderung mengarah kepada *overfitting* yang artinya model yang dibangun kurang baik dalam memprediksi hasilnya.

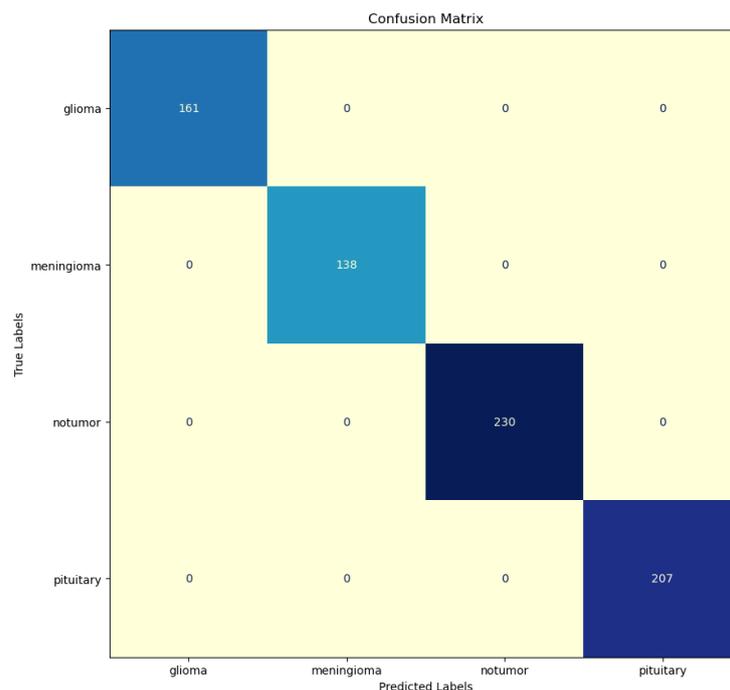
C. Pengaruh Jumlah Epoch

Salah satu parameter yang mempengaruhi performa model CNN adalah jumlah *epoch*. *Epoch* sendiri merupakan satu siklus atau putaran di mana algoritma *machine learning* belajar dari seluruh *dataset* pelatihan.[17] Proses pembelajaran yang berulang ini bertujuan untuk mencapai nilai konvergensi yang baik. Namun, tidak ada patokan pasti mengenai jumlah *epoch* yang harus digunakan. Oleh karena itu, penulis melakukan uji coba parameter *epoch* dengan kelipatan 5 hingga 20. Berikut adalah hasil uji model CNN dengan berbagai perubahan parameter *epoch*.

TABEL 4
PERBANDINGAN MATRIK EVALUASI DENGAN JUMLAH EPOCH

Jenis Dataset Augmentasi	Epoch	Accuracy	Precision	Recal Score	F1 Score	Loss Error	Time
Dataset tanpa augmentasi	5	78.12%	78.59%	78.12%	77.41%	0.29%	0:47:06
	10	84.38%	84.75%	84.18%	84.18%	0.28%	5:12:37
	15	87.50%	92.05%	87.50%	88.06%	0.22%	6:57:39
	20	90.62%	93.75%	90.62%	91.26%	0.27%	6:28:57
Augmentasi Vertikal & Horizontal Flip	5	90.62%	90.76%	90.62%	90.49%	0.27%	0:39:48
	10	96.88%	97.32%	96.88%	96.90%	0.22%	1:09:59
	15	84.38%	85.90%	84.38%	84.50%	0.13%	1:53:44
	20	100.00%	100.00%	100.00%	100.00%	0.16%	1:24:15
Augmentasi rotation (20°)	5	90.62%	93.44%	90.62%	90.71%	0.29%	0:47:06
	10	84.38%	85.24%	84.38%	84.32%	0.18%	0:48:36
	15	93.75%	94.27%	93.75%	93.82%	0.20%	1:10:15
	20	84.38%	92.19%	84.38%	85.51%	0.31%	1:37:37
Augmentasi scaling image (256x256)	5	93.75%	96.88%	93.75%	94.60%	0.26%	0:53:08
	10	90.62%	91.39%	90.62%	90.31%	0.19%	1:17:11
	15	96.88%	97.22%	96.88%	96.88%	0.14%	2:23:34
	20	90.62%	90.89%	90.62%	90.56%	0.22%	3:52:56

Dari tabel diatas kita dapat melihat dari setiap jenis *dataset* baik yang asli maupun *dataset* augmentasi terlihat peningkatan dan penurunan secara fluktuatif dari setiap rentang epoch 5 sampai 20, artinya dari hasil tersebut penulis dapat menyimpulkan bahwa *epoch* mempunyai pengaruh cukup penting dalam membangun model CNN.



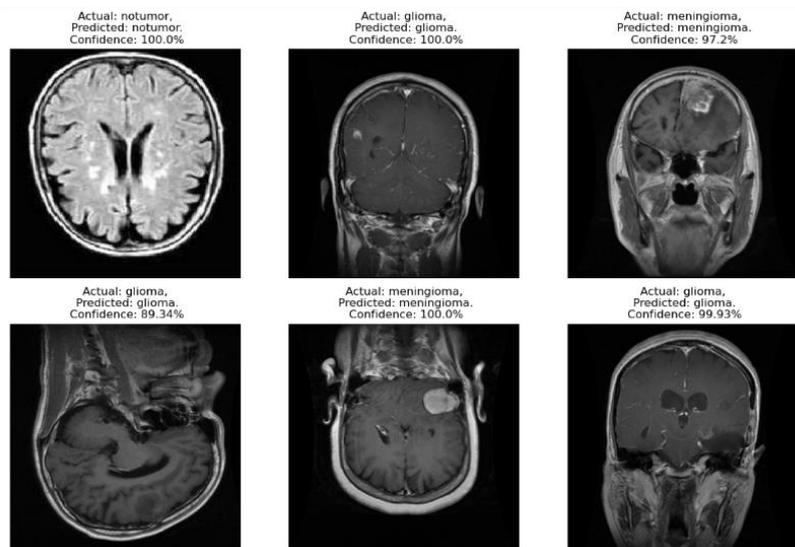
Berikut confusion matrik dari model terbaik dengan nilai akurasi, presisi, recall dan F1 Score 100% pada model ini:

Dari gambar diatas kita dapat melihat bahwa hasil dari evaluasi prediksi dengan *confusion matrix* adalah 100% sesuai dengan kelas aktual nya dimana prediksi dari 161 citra kelas *glioma*, 128 citra kelas *meningioma*, 230 citra kelas notumor serta 207 citra kelas pituitary tepat sesuai dengan kelas aktualnya.

D. Hasil Uji Prediksi Model

Untuk menguji model yang sudah ada, penulis mencoba untuk menguji model tersebut dengan dataset yang ada, berikut contoh hasil uji dari model tersebut:

Gambar 4. Confusion Matrik Klasifikasi Tumor Otak



Gambar 5. Contoh Uji Prediksi Model Kalsifikasi Tumor Otak

Gambar tersebut menampilkan hasil klasifikasi tumor otak menggunakan model CNN terbaik pada eksperimen pada beberapa gambar MRI otak. Setiap gambar menampilkan prediksi model, label aktual, serta tingkat kepercayaan (*confidence*) dari prediksi tersebut. Dari Gambar pertama menunjukkan prediksi MRI otak kelas *notumor* yang memiliki tingkat *confidence* 100% dan mengklasifikasikannya sebagai kelas *no tumor*. Gambar kedua menunjukkan MRI dengan tumor *glioma* yang juga diklasifikasikan sebagai *glioma* oleh model dengan tingkat *confidence* 100%. Gambar ketiga adalah MRI dengan tumor *meningioma* yang diklasifikasikan sebagai *meningioma* dengan tingkat *confidence* 97.24%. Gambar keempat memperlihatkan MRI otak dengan *glioma*, yang diklasifikasikan dengan benar sebagai *glioma* dengan kepercayaan 89.34%. Gambar kelima menampilkan MRI otak dengan *meningioma* yang diklasifikasikan sebagai *meningioma* dengan tingkat *confidence* 100%. Terakhir, gambar keenam menunjukkan MRI otak dengan *glioma* yang diklasifikasikan dengan benar sebagai

glioma dengan *confidence* 99.93%. Gambar ini menunjukkan kinerja model CNN dalam mengklasifikasikan berbagai jenis tumor otak dengan tingkat kepercayaan yang tinggi.

V. PEMBAHASAN

Penelitian ini menyoroti beberapa aspek penting dalam penggunaan *Convolutional Neural Networks (CNN)* untuk klasifikasi tumor otak dari citra MRI, dengan penekanan pada teknik augmentasi data dan pengaturan parameter epoch. Teknik augmentasi data terbukti menjadi faktor kunci dalam meningkatkan kinerja model CNN. Dengan menggunakan berbagai teknik augmentasi seperti rotasi, flipping, dan scaling, penelitian ini berhasil meningkatkan keragaman data pelatihan tanpa mengubah label asli, yang merupakan masalah umum dalam citra medis dengan jumlah data yang terbatas. Teknik augmentasi ini memungkinkan model untuk menjadi lebih robust dan mampu mengenali pola yang lebih bervariasi dalam citra medis, sehingga meningkatkan akurasi klasifikasi.

Pengaturan parameter epoch juga memainkan peran penting dalam kinerja model CNN. Dalam penelitian ini, uji coba dengan rentang epoch dari 5 hingga 20 menunjukkan bahwa jumlah epoch yang tepat dapat secara signifikan mempengaruhi hasil model. Proses pembelajaran berulang kali atau epoch ini bertujuan untuk mencapai nilai konvergensi yang optimal, di mana model tidak hanya mempelajari pola dari data pelatihan tetapi juga mampu menggeneralisasi dengan baik pada data baru. Hasil penelitian menunjukkan bahwa dengan jumlah epoch yang tepat, model dapat mencapai akurasi yang sangat tinggi, dengan beberapa kombinasi augmentasi data dan epoch tertentu mencapai akurasi hingga 100%.

Confusion matrix yang dihasilkan dari model terbaik memberikan gambaran jelas tentang kemampuan model dalam mengklasifikasikan berbagai jenis tumor otak. Model mampu memprediksi dengan akurasi tinggi pada kelas-kelas tumor seperti glioma, meningioma, notumor, dan pituitary. Prediksi yang tepat pada 161 citra kelas glioma, 128 citra kelas meningioma, 230 citra kelas notumor, dan 207 citra kelas pituitary menunjukkan bahwa model CNN yang dikembangkan dalam penelitian ini memiliki tingkat presisi yang tinggi dalam mengidentifikasi berbagai jenis tumor otak. Hal ini menunjukkan bahwa teknik augmentasi data yang digunakan tidak hanya meningkatkan jumlah data pelatihan tetapi juga kualitas prediksi model.

Selain itu, penelitian ini juga memberikan wawasan tentang pentingnya pemilihan teknik augmentasi yang tepat untuk jenis data tertentu. Setiap teknik augmentasi memiliki dampak yang berbeda terhadap kinerja model, dan penelitian ini menunjukkan bahwa *augmentasi* vertikal dan horizontal flip memberikan hasil yang paling optimal. Temuan ini dapat menjadi panduan bagi penelitian di masa depan untuk memilih dan mengkombinasikan teknik *augmentasi* yang sesuai dengan jenis data yang digunakan.

Secara keseluruhan, penelitian ini memberikan kontribusi penting dalam bidang klasifikasi citra medis dengan menunjukkan bahwa kombinasi teknik augmentasi data dan pengaturan parameter epoch dapat secara signifikan meningkatkan kinerja model CNN. Temuan ini diharapkan dapat mendorong penelitian lebih lanjut untuk mengeksplorasi teknik augmentasi data yang lebih inovatif dan pengaturan parameter yang lebih optimal, guna meningkatkan akurasi dan efisiensi model dalam diagnosis medis. Dengan demikian, penelitian ini tidak hanya memberikan solusi praktis untuk masalah keterbatasan data dalam klasifikasi tumor otak tetapi juga membuka jalan bagi perkembangan teknologi diagnostik yang lebih canggih dan andal.

VI. KESIMPULAN

Dari hasil penelitian ini penulis dapat menyimpulkan bahwa penggunaan metode *Convolutional Neural Networks (CNN)* untuk klasifikasi tumor otak menunjukkan potensi yang signifikan, seperti yang telah dibuktikan oleh studi eksperimental yang dilakukan. Studi ini secara sistematis memvariasikan parameter, termasuk jumlah *epoch* dan penerapan berbagai teknik *augmentasi* data, untuk meningkatkan performa model.

Penulis melakukan uji coba dengan jumlah *epoch* yang bervariasi, mulai dari 5, 10, 15 hingga 20, dan menggunakan teknik augmentasi data seperti rotasi, penskalaan, translasi, dan refleksi citra. Hasil penelitian menunjukkan bahwa peningkatan jumlah epoch dalam rentang tertentu dan penerapan metode augmentasi data secara substansial meningkatkan akurasi dan ketahanan model. Peningkatan ini terjadi karena proses pembelajaran yang lebih banyak memberikan kesempatan bagi model untuk memahami pola yang lebih kompleks dalam data.

Teknik augmentasi data juga memainkan peran penting dalam mengatasi keterbatasan jumlah citra medis berlabel yang tersedia. Dengan memperluas set data pelatihan secara signifikan, model menjadi lebih robust dan mampu menggeneralisasi lebih baik pada data yang belum pernah dilihat sebelumnya. Hasilnya, akurasi model dalam mengklasifikasikan tumor otak meningkat secara signifikan, menjadikan pendekatan ini sebagai alat diagnostik yang lebih akurat dan andal di bidang medis.

Secara keseluruhan, penelitian ini menunjukkan bahwa dengan mengoptimalkan parameter model dan memanfaatkan teknik augmentasi data, performa CNN dalam mendiagnosis tumor otak dapat ditingkatkan secara signifikan, memberikan kontribusi penting bagi perkembangan teknologi diagnostik medis yang lebih canggih dan efisien.

REFERENCE

- [1] H. Pengobatan Klinis, M. Ghozali, H. Sumarti, K. Kunci, T. Otak, and O. Dewasa, "Pengobatan Klinis Tumor Otak pada Orang Dewasa," *Jurnal Pendidikan Fisika dan Fisika Terapan*, vol. 6, no. 1, p. 2020, 2020.
- [2] "Apa itu Tumor Otak? Ini Penyebab, Gejala, dan Pengobatannya ." Accessed: Jul. 31, 2024. [Online]. Available: https://www.siloamhospitals.com/informasi-siloam/artikel/apa-itu-tumor-otak#mctoc_1gs9brk413if
- [3] "Brain MRI." Accessed: Jul. 31, 2024. [Online]. Available: <https://my.clevelandclinic.org/health/diagnostics/22966-brain-mri>
- [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] A. S. Febrianti, T. A. Sardjono, and A. F. Babgei, "Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine," *JURNAL TEKNIK ITS*, vol. 9, no. 1, pp. 118–123, 2020.
- [6] F. Nurona Cahya *et al.*, "SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)." [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [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] 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.
- [9] D. Gunawan and H. Setiawan, "Convolutional Neural Network dalam Analisis Citra Medis," 2022.
- [10] W. Budiharto and B. S. Abbas, *Panduan Riset & Publikasi Penelitian bagi Akademisi*, 1st ed. Yogyakarta: Andi Publisher, 2023.
- [11] D. Bhatt *et al.*, "Cnn variants for computer vision: History, architecture, application, challenges and future scope," Oct. 01, 2021, *MDPI*. doi: 10.3390/electronics10202470.
- [12] 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.
- [13] 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>
- [14] Q. Wen *et al.*, "Time Series Data Augmentation for Deep Learning: A Survey," in *IJCAI International Joint Conference on Artificial Intelligence*, International Joint Conferences on Artificial Intelligence, 2021, pp. 4653–4660. doi: 10.24963/ijcai.2021/631.
- [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] N. Das and S. Das, "Epoch and accuracy based empirical study for cardiac MRI segmentation using deep learning technique," *PeerJ*, vol. 11, p. e14939, Mar. 2023, doi: 10.7717/peerj.14939.