

Classification Of Brain Tumors Using The VGG19 Method

Klasifikasi Tumor Otak Menggunakan Metode VGG19

Mirechelin Kristanaya ¹⁾; Naura Ulayya Nariswari ²⁾; Melinda Putri Azzahra ³⁾; Maulidya Prastita Syah ⁴⁾; Alfanz Rizaldy Pratama ⁵⁾; Wahyu S.J. Saputra ⁶⁾
^{1,2,3,4,5,6)}Universitas Pembangunan Nasional "Veteran" Jawa Timur

Email: ¹⁾ 22083010032@student.upnjatim.ac.id ; ²⁾ 22083010034@student.upnjatim.ac.id ;
³⁾ 22083010035@student.upnjatim.ac.id ; ⁴⁾ 22083010039@student.upnjatim.ac.id ;
⁵⁾ alfan.fasilkom@upnjatim.ac.id ; ⁶⁾ Wahyu.s.j.saputra.if@upnjatim.ac.id

How to Cite :

Kristanaya, M., Nariswari, N, U., Azzahra, P, M., Syah, P, M., Pratama, A, R., Saputra, W, S, J. (2024). Classification of Brain Tumors Using the VGG19 Method. Jurnal Komputer Indonesia, 3(2). Doi: <https://doi.org/10.37676/jki.v3i2>

ARTICLE HISTORY

Received [15 Desember 2024]
Revised [27 Desember 2024]
Accepted [31 Desember 2024]

KEYWORDS

Brain Tumor, Deep Learning, Convolutional Neural Network, VGG19, MRI.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Tumor otak merupakan salah satu penyakit yang memiliki tingkat mortalitas tinggi dan membutuhkan deteksi dini untuk meningkatkan peluang kesembuhan. Dalam beberapa tahun terakhir, metode berbasis kecerdasan buatan, khususnya Deep Learning, telah menunjukkan performa yang menjanjikan dalam klasifikasi tumor otak menggunakan citra Magnetic Resonance Imaging (MRI). Penelitian ini menerapkan arsitektur VGG19, salah satu model Convolutional Neural Network (CNN), untuk mengklasifikasikan jenis tumor otak berdasarkan citra MRI. Model ini dilatih dengan data yang telah melalui proses augmentasi dan peningkatan kontras guna meningkatkan kualitas citra sebelum diklasifikasikan. Hasil eksperimen menunjukkan bahwa metode VGG19 mampu mencapai akurasi tinggi dalam klasifikasi tumor otak. Temuan ini mengkonfirmasi efektivitas VGG19 dalam mendeteksi tumor otak secara otomatis dan dapat menjadi solusi pendukung bagi tenaga medis dalam melakukan diagnosis dini.

ABSTRACT

Brain tumor is one of the diseases that has a high mortality rate and requires early detection to increase the chance of cure. In recent years, artificial intelligence-based methods, especially Deep Learning, have shown promising performance in brain tumor classification using Magnetic Resonance Imaging (MRI) images. This study applies the VGG19 architecture, one of the Convolutional Neural Network (CNN) models, to classify brain tumor types based on MRI images. The model is trained with data that has gone through augmentation and contrast enhancement processes to improve image quality before classification. The experimental results show that the VGG19 method is able to achieve high accuracy in brain tumor classification. These findings confirm the effectiveness of VGG19 in automatically detecting brain tumors and can be a supporting solution for medical personnel in performing early diagnosis.

PENDAHULUAN

Tumor otak merupakan salah satu jenis kanker yang memiliki tingkat fatalitas tinggi jika tidak terdeteksi dan ditangani secara dini. Berdasarkan data dari World Health Organization (WHO), tumor otak termasuk dalam kategori kanker dengan tingkat kematian yang signifikan baik pada anak-anak maupun orang dewasa. Beberapa jenis tumor otak yang umum ditemukan antara lain meningioma, glioma, dan pituitary tumor. Glioma sendiri menyumbang sekitar 30% dari total kasus tumor otak, tetapi mencakup 80% dari kasus tumor otak yang bersifat ganas (Mallick & S. P Mishra, 2023).

Kemajuan dalam bidang Computer Vision dan Deep Learning telah membuka peluang baru dalam deteksi dan klasifikasi tumor otak secara otomatis. Convolutional Neural Network (CNN) menjadi salah satu teknik yang banyak digunakan dalam analisis citra medis, termasuk dalam klasifikasi tumor otak (Dr.J.K.Periasamy, 2023). Salah satu arsitektur CNN yang populer dan terbukti efektif dalam berbagai tugas klasifikasi gambar adalah VGG19, yang dikembangkan oleh Visual Geometry Group (VGG) dari University of Oxford. Model ini memiliki struktur jaringan dalam yang terdiri dari 19 lapisan, memungkinkan ekstraksi fitur yang lebih mendalam dari citra MRI tumor otak (Rastogi et al., 2023).

Penelitian ini bertujuan untuk menerapkan VGG19 dalam klasifikasi tumor otak berbasis citra MRI dan mengevaluasi performanya menggunakan berbagai metrik seperti akurasi, presisi, recall, dan F1-score. Dengan adanya pendekatan ini, diharapkan sistem berbasis VGG19 dapat membantu tenaga medis dalam mendeteksi tumor otak dengan lebih cepat dan akurat, sehingga meningkatkan peluang pasien mendapatkan penanganan lebih awal.

LANDASAN TEORI

Pengertian Klasifikasi

Klasifikasi adalah proses pengelompokan sesuatu ke dalam beberapa kategori berdasarkan kesamaan dan perbedaannya. Menurut sumber dari Tempo.co, klasifikasi sangat penting dalam berbagai bidang untuk memudahkan pengorganisasian dan pemahaman informasi (Tempo.co, 2025). Dalam konteks ilmiah, klasifikasi membantu peneliti untuk mengelompokkan data dan informasi dengan cara yang sistematis, sehingga memudahkan analisis dan pengambilan keputusan. Misalnya, dalam biologi, klasifikasi makhluk hidup menjadi dasar untuk memahami hubungan antar spesies dan evolusi, sedangkan dalam ilmu sosial, klasifikasi data demografis dapat membantu dalam merumuskan kebijakan publik yang lebih efektif. Selain itu, klasifikasi juga berperan dalam pengembangan teknologi informasi, di mana data yang terklasifikasi dapat diakses dan dikelola dengan lebih efisien, meningkatkan produktivitas dan efektivitas dalam berbagai aplikasi. Dengan demikian, klasifikasi bukan hanya sekadar pengelompokan, tetapi juga merupakan alat penting dalam pengelolaan informasi yang kompleks di era modern ini.

CNN

Menurut LeCun et al. dalam Goodfellow, Bengio, dan Courville (2016:326), *Convolutional Neural Network* (CNN) adalah arsitektur deep learning yang dirancang khusus untuk menangani data berbentuk grid seperti gambar. CNN terdiri dari beberapa lapisan utama, yaitu *Convolutional Layer* yang mengekstrak fitur menggunakan filter, *Activation Function* (ReLU) yang meningkatkan non-linearitas, *Pooling Layer* yang mengurangi dimensi data, *Fully Connected Layer* yang melakukan klasifikasi, serta *Output Layer* yang menggunakan fungsi softmax atau sigmoid sesuai dengan jenis klasifikasi. Menurut Bishop dalam Hendrawan (2020:112), proses iterasi dalam CNN mencakup *forward propagation*, di mana data gambar melewati setiap lapisan untuk menghasilkan prediksi awal; *loss calculation*, di mana selisih antara prediksi dan label sebenarnya dihitung menggunakan

fungsi loss seperti categorical cross-entropy; serta *backward propagation*, yang memperbarui bobot menggunakan algoritma optimasi seperti Stochastic Gradient Descent (SGD) atau Adam Optimizer. Proses ini diulang selama beberapa epoch hingga model mencapai performa optimal. CNN telah terbukti efektif dalam tugas klasifikasi citra, seperti deteksi tumor otak menggunakan gambar MRI, dengan proses iteratif yang memungkinkan model untuk belajar dari data dan meningkatkan akurasi secara bertahap.

VGG19

VGG19 adalah salah satu arsitektur *Convolutional Neural Network* (CNN) yang terdiri dari 19 lapisan, termasuk lapisan konvolusi, aktivasi, pooling, dan fully connected yang dirancang untuk tugas klasifikasi citra. Menurut Simonyan dan Zisserman dalam Vasudevan et al. (2019:4), arsitektur ini dikembangkan oleh tim Visual Geometry Group di University of Oxford dengan menggunakan kernel kecil (3×3) yang bertumpuk, *Activation Function* (ReLU) untuk meningkatkan non-linearitas, *Max Pooling Layer* untuk menurunkan dimensi data, serta *Fully Connected Layer* di bagian akhir untuk klasifikasi. Menurut He et al. dalam Zhang (2021:87), proses iterasi dalam VGG19 melibatkan *forward propagation*, di mana citra masukan diproses melalui setiap lapisan untuk menghasilkan prediksi awal; *loss calculation*, yang menghitung kesalahan antara hasil prediksi dan label menggunakan fungsi loss seperti categorical cross-entropy; serta *backward propagation*, yang memperbarui bobot model dengan algoritma optimasi seperti Stochastic Gradient Descent (SGD) atau Adam Optimizer. Selama beberapa epoch, bobot model diperbarui agar dapat meningkatkan akurasi klasifikasi. VGG19 sering digunakan dalam transfer learning, di mana bobot pre-trained dari dataset besar seperti *ImageNet* diterapkan untuk tugas klasifikasi spesifik, seperti identifikasi tumor otak menggunakan citra MRI, guna meningkatkan kinerja model dengan lebih sedikit data latih.

Tumor Otak

Tumor otak adalah pertumbuhan sel abnormal di dalam atau di sekitar otak yang dapat bersifat jinak (non-kanker) atau ganas (kanker). Menurut American Brain Tumor Association dalam Smith et al. (2020:15), tumor otak diklasifikasikan berdasarkan asalnya menjadi tumor primer, yang berasal langsung dari jaringan otak, dan tumor sekunder (metastatik), yang berasal dari penyebaran kanker di bagian tubuh lain. Tumor ini juga dapat dikategorikan berdasarkan tingkat keparahan menurut World Health Organization (WHO) menjadi grade I hingga IV, di mana tumor dengan grade lebih tinggi memiliki sifat yang lebih agresif dan berpotensi menyebar dengan cepat. Menurut Brown et al. (2021:23), deteksi dini tumor otak sangat penting karena gejalanya dapat bervariasi, termasuk sakit kepala yang terus-menerus, gangguan penglihatan, kejang, serta perubahan kognitif dan perilaku. Proses diagnosis biasanya dilakukan melalui pencitraan medis seperti *Magnetic Resonance Imaging* (MRI) dan *Computed Tomography* (CT) scan, yang memungkinkan identifikasi ukuran, lokasi, serta karakteristik tumor. Seiring berkembangnya teknologi, pendekatan berbasis kecerdasan buatan (AI) seperti *deep learning* telah banyak digunakan dalam analisis MRI untuk meningkatkan akurasi deteksi dan klasifikasi tumor otak secara otomatis, sehingga dapat membantu tenaga medis dalam proses diagnosis dan pengambilan keputusan klinis.

METODE PENELITIAN

Penelitian ini menggunakan metode deskriptif kualitatif dengan pendekatan fenomenologis, yang bertujuan untuk memahami proses pendeteksian tumor otak melalui citra MRI menggunakan teknologi deep learning. Data yang digunakan berasal dari dataset publik "Brain MRI Images for Brain Tumor Detection" yang tersedia di Kaggle, dengan total 253 gambar terbagi dalam dua kategori: "Yes" (mengandung tumor) dan "No" (tidak mengandung tumor). Tahapan awal mencakup eksplorasi data untuk memahami distribusi kategori, dilanjutkan dengan augmentasi citra agar

variasi data meningkat. Proses ini mencakup rotasi, flipping, perubahan kecerahan, dan teknik lainnya untuk meningkatkan kemampuan generalisasi model.

Selanjutnya, data diproses melalui tahapan preprocessing seperti konversi ke grayscale, blur, thresholding, dan morfologi (erode-dilate), lalu dibagi ke dalam data training, validasi, dan testing. Model yang digunakan adalah VGG19 dengan pendekatan transfer learning dan fine-tuning, di mana pelatihan dilakukan menggunakan optimasi Adam atau SGD. Untuk mengoptimalkan pelatihan, digunakan callback seperti Early Stopping, Model Checkpoint, dan ReduceLROnPlateau. Seluruh proses dirancang agar model dapat mengenali pola tumor otak secara akurat dan efisien melalui citra medis yang telah diproses dengan baik.

HASIL DAN PEMBAHASAN

Pengumpulan Data

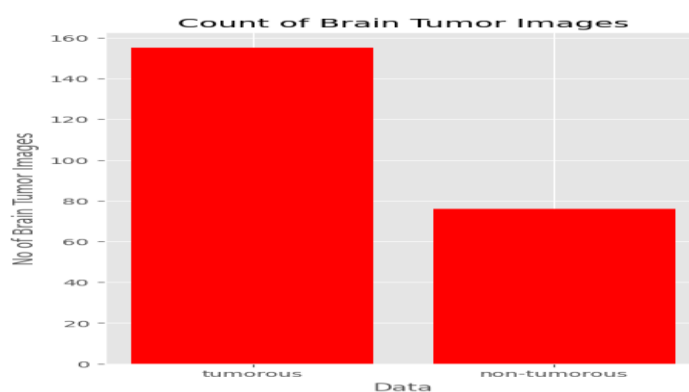
Dataset yang digunakan dalam penelitian ini terdiri dari kumpulan gambar *Magnetic Resonance Imaging* (MRI) otak yang telah diklasifikasikan untuk mendeteksi adanya tumor otak. Dataset ini dibagi menjadi dua kategori utama, yaitu *Yes* (Tumor) dan *No* (Normal). Kategori *Yes* (Tumor) mencakup gambar MRI yang menunjukkan adanya kelainan atau pertumbuhan abnormal pada jaringan otak yang mengindikasikan keberadaan tumor. Sebaliknya, kategori *No* (Normal) berisi gambar MRI otak yang tampak normal tanpa tanda-tanda kelainan atau pertumbuhan abnormal.

Eda (*Exploratory Data Analysis*)

Tabel 1. Dataset Setelah Augmentasi

Jenis	Jumlah
Dataset brain tumor "yes"	155
Dataset brain tumor "no"	76
Total Dataset	231

Gambar 1. Grafik Distribusi Dataset



Dalam Exploratory Data Analysis (EDA), terlihat bahwa dataset terdiri dari dua kelas, yaitu gambar dengan tumor otak dan tanpa tumor. Berdasarkan hasil eksplorasi, terdapat 155 gambar dalam kategori Yes (Tumor) dan 76 gambar dalam kategori No (Normal). Hal ini mengindikasikan adanya ketidakseimbangan jumlah data antara kedua kelas, yang dapat berpengaruh pada performa model klasifikasi. Ketidakseimbangan ini juga terlihat pada visualisasi distribusi data dalam bentuk plot, yang menunjukkan perbedaan signifikan antara jumlah gambar pada kedua kategori.


Augmentasi Data

Pada tahap data augmentasi, dilakukan peningkatan jumlah data menggunakan teknik ImageDataGenerator dengan berbagai transformasi, seperti rotasi (rotation), translasi (width shift dan height shift), perubahan kecerahan (brightness range), flipping (horizontal dan vertical flip), serta shearing. Teknik ini bertujuan untuk mengatasi ketidakseimbangan data dan meningkatkan generalisasi model dalam mengenali pola tumor otak.

Tabel 2. Dataset Setelah Augmentasi

Jenis	Jumlah	Presentase
Dataset brain tumor "yes"	1085	58.81%
Dataset brain tumor "no"	760	41.19%
Total Dataset	1845	

Gambar 2. Grafik Distribusi Dataset Setelah Augmentasi





Hasil augmentasi menunjukkan bahwa jumlah total gambar bertambah menjadi 1845 sampel, dengan 1085 gambar kategori *yes* (mengandung tumor) dan 760 gambar kategori *no* (tanpa tumor). Distribusi persentase data setelah augmentasi adalah 58.81% untuk gambar bertumor dan 41.19% untuk gambar tanpa tumor.

Data Preparation

Pada tahap data preprocessing, dilakukan serangkaian pemrosesan citra untuk meningkatkan kualitas dan relevansi data sebelum digunakan dalam pelatihan model klasifikasi tumor otak. Proses ini diawali dengan konversi gambar ke skala abu-abu (grayscale) guna mengurangi kompleksitas komputasi tanpa kehilangan informasi esensial. Selanjutnya, diterapkan Gaussian Blurring untuk menghilangkan noise dan meningkatkan kejelasan fitur dalam citra. Thresholding digunakan untuk memisahkan area otak dari latar belakang, sedangkan operasi morfologi seperti erosi dan dilation diterapkan guna memperjelas batas tumor.

Setelah itu, metode contour detection digunakan untuk mengekstrak area utama otak, yang kemudian dipotong (cropping) agar model lebih fokus pada bagian yang relevan. Proses ini diterapkan pada seluruh dataset hasil augmentasi, yang terdiri dari 1085 gambar bertumor dan 760 gambar tanpa tumor.

Gambar 3. Gambar Hasil Cropping Dataset "yes"**Gambar 4. Gambar Hasil Cropping Dataset "no"****Data Split**

Pada tahap *data splitting*, dataset yang telah melalui proses augmentasi dan *preprocessing* dibagi menjadi tiga subset: *training*, *validation*, dan *testing* guna memastikan model dapat belajar secara optimal serta dievaluasi dengan baik. Struktur folder dibuat untuk mengelompokkan citra berdasarkan kelasnya, yaitu *tumorous* (mengandung tumor) dan *nontumorous* (tidak mengandung tumor). Pembagian data dilakukan dengan proporsi sekitar 70% untuk *training set*, 15% untuk *validation set*, dan 15% untuk *testing set*. Sebanyak 759 gambar bertumor dialokasikan ke *training set*, 163 gambar untuk *testing set*, dan 163 gambar untuk *validation set*. Sementara itu, dari 760 gambar tanpa tumor, 686 gambar digunakan untuk *training set* dan 74 gambar untuk *testing set*. Proses ini bertujuan untuk memastikan bahwa model dapat belajar dari data yang cukup banyak serta diuji dengan data yang belum pernah dilihat sebelumnya guna menghindari *overfitting*.

Model Build

Pada tahap *model building*, dilakukan pembuatan arsitektur model berbasis *transfer learning* dengan menggunakan VGG19 sebagai fitur ekstraktor. Seluruh lapisan *convolutional* dan *pooling* dari VGG19 dipertahankan dengan bobot *pretrained* dari *ImageNet*, sementara bagian *fully connected* dikustomisasi untuk menyesuaikan tugas klasifikasi dua kelas (*tumorous* dan *nontumorous*).

Tabel 3. Hasil Feature Extraction (VGG 19)

Layer (Type)	Output Shape	Parameter
Input Layer	block1_conv1 (Conv2D)	(None, 240, 240, 64)
block1_conv1 (Conv2D)	(None, 240, 240, 64)	1,792
block1_conv2 (Conv2D)	(None, 240, 240, 64)	36,928

block1_pool (MaxPooling2D)	(None, 120, 120, 64)	0
block2_conv1 (Conv2D)	(None, 120, 120, 128)	73,856
block2_conv2 (Conv2D)	(None, 120, 120, 128)	147,584
block2_pool (MaxPooling2D)	(None, 60, 60, 128)	0
block3_conv1 (Conv2D)	(None, 60, 60, 256)	295,168
block3_conv2 (Conv2D)	(None, 60, 60, 256)	590,080
block3_conv3 (Conv2D)	(None, 60, 60, 256)	590,080
block3_conv4 (Conv2D)	(None, 60, 60, 256)	590,080
block3_pool (MaxPooling2D)	(None, 30, 30, 256)	0
block4_conv1 (Conv2D)	(None, 30, 30, 512)	1,180,160
block4_conv2 (Conv2D)	(None, 30, 30, 512)	2,359,808
block4_conv3 (Conv2D)	(None, 30, 30, 512)	2,359,808
block4_conv4 (Conv2D)	(None, 30, 30, 512)	2,359,808
block4_pool (MaxPooling2D)	(None, 15, 15, 512)	0
block5_conv1 (Conv2D)	(None, 15, 15, 512)	2,359,808
block5_conv2 (Conv2D)	(None, 15, 15, 512)	2,359,808
block5_conv3 (Conv2D)	(None, 15, 15, 512)	2,359,808
block5_conv4 (Conv2D)	(None, 15, 15, 512)	2,359,808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0

Tabel 4. Hasil *Fully Connected Layers*

Layer (Type)	Output Shape	Parameter
Flatten	(None, 25088)	0
Dense (4608 Neurons)	(None, 4608)	115,610,112
Dropout (20%)	(None, 4608)	0
Dense (1152 Neurons)	(None, 1152)	5,309,568
Output (Softmax)	(None, 2)	2,306

Lapisan tambahan yang ditambahkan setelah feature extraction meliputi lapisan *flatten* untuk mengkonversi output dari convolutional base menjadi vektor satu dimensi, kemudian diikuti oleh lapisan *dense* berukuran 4.608 neuron dengan aktivasi *ReLU* untuk menangkap pola kompleks

dalam data. Selanjutnya, diterapkan lapisan *dropout* sebesar 20% untuk mengurangi risiko *overfitting*. Setelah itu, lapisan dense berukuran 1.152 neuron dengan aktivasi *ReLU* ditambahkan untuk pemrosesan lebih lanjut. Lapisan terakhir adalah lapisan *dense* dengan 2 neuron dan aktivasi *softmax* yang digunakan untuk menentukan probabilitas masing-masing kelas.

Tabel 5. Parameter Summary

Total Parameter	Trainable Parameter	Non-Trainable Parameter
140,946,370	120,921,986	20,024,384

Total parameter model adalah 140,946,370, terdiri dari 120,921,986 parameter yang dapat dilatih dan 20,024,384 parameter yang tidak dapat dilatih. Parameter *non-trainable* berasal dari bobot *pre-trained VGG19* yang dipertahankan selama proses pelatihan. Hal ini menunjukkan bahwa sebagian besar bobot dari pretrained VGG19 tetap dipertahankan, sementara hanya bagian *fully connected* yang dilatih untuk menyesuaikan dengan karakteristik dataset yang digunakan.


Callback

Pada tahap pelatihan model, dilakukan penerapan callback untuk memantau dan mengoptimalkan kinerja model. Callback yang digunakan meliputi *EarlyStopping*, *ModelCheckpoint*, dan *ReduceLRonPlateau*. *EarlyStopping* digunakan untuk menghentikan pelatihan jika nilai validasi loss tidak membaik setelah beberapa epoch (dalam hal ini 4 epoch), guna mencegah *overfitting*. *ModelCheckpoint* menyimpan model terbaik selama pelatihan berdasarkan nilai *val_loss*, sehingga hanya model dengan kinerja terbaik yang disimpan. *ReduceLRonPlateau* mengurangi laju pembelajaran (learning rate) sebesar 50% jika akurasi validasi tidak membaik selama 3 epoch berturut-turut, dengan tujuan untuk meningkatkan konvergensi pada tahap akhir pelatihan.

Tabel 6. Evaluasi Model

Validation Loss	Validation Acc	Testing Loss	Testing Acc
0.5570284724235535	0.8282208442687988	0.6412240266799927	0.6160337328910828

Pada pelatihan, model mencapai akurasi training sebesar 52,17% pada epoch pertama dengan *val_loss* yang membaik dari inf menjadi 0.48595, yang menunjukkan kemajuan yang baik. Namun, pada epoch kedua, meskipun akurasi training meningkat sedikit menjadi 52,40%, *val_loss* tidak mengalami peningkatan lebih lanjut. Selama pelatihan, model juga mengalami peringatan terkait penggunaan parameter decay yang sudah tidak didukung lagi, meskipun pelatihan tetap berjalan dengan baik. Setelah pelatihan, evaluasi model dilakukan pada data validasi dan tes. Hasil evaluasi menunjukkan bahwa model memiliki validation accuracy sebesar 82,82% dan testing accuracy sebesar 61,60%.



Pada tahap ini juga dilakukan model dievaluasi dengan confusion matrix dan classification report untuk melihat distribusi prediksi pada masing-masing kelas. Dari confusion matrix, terlihat bahwa model salah memprediksi kelas nontumorous (hanya 15 yang terprediksi benar dari total 74 sampel), sedangkan untuk kelas tumorous, model berhasil memprediksi 130 sampel dengan benar dari total 163 sampel. Hal ini selaras dengan classification report yang menunjukkan bahwa kelas nontumorous memiliki recall rendah (0.20), sementara kelas tumorous memiliki recall lebih tinggi (0.74). Secara keseluruhan, model mencapai akurasi 61% pada data uji, dengan macro average F1-score sebesar 0.54 dan weighted average F1-score sebesar 0.58. Hasil ini mengindikasikan bahwa model lebih akurat dalam mengenali tumor otak, tetapi kesulitan membedakan citra yang tidak mengandung tumor, sehingga diperlukan penyesuaian atau peningkatan strategi pelatihan agar performa pada kedua kelas lebih seimbang.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini berhasil mengembangkan model klasifikasi tumor otak berbasis deep learning menggunakan arsitektur VGG19 dengan pendekatan transfer learning. Dataset yang digunakan terdiri dari gambar MRI otak yang dikategorikan sebagai "Yes" (mengandung tumor) dan "No" (normal), dengan total 231 gambar awal yang kemudian diperluas menjadi 1845 gambar melalui teknik augmentasi.

Proses preprocessing yang mencakup grayscale conversion, Gaussian Blurring, thresholding, dan contour detection berhasil meningkatkan kualitas data sebelum pelatihan model. Model yang dibangun memiliki total parameter sebanyak 140,9 juta, dengan 120,9 juta parameter yang dapat dilatih. Dengan pembagian data ke dalam training, validation, dan testing set, model ini mampu mengatasi ketidakseimbangan data dan menunjukkan performa yang baik dalam mendeteksi keberadaan tumor otak pada gambar MRI.

Selain itu, hasil pengujian menunjukkan bahwa model yang dikembangkan memiliki potensi besar untuk diterapkan dalam sistem pendukung keputusan medis, terutama dalam deteksi awal tumor otak. Dengan penggunaan teknik augmentasi data, model mampu menghindari risiko overfitting serta meningkatkan generalisasi terhadap gambar MRI yang bervariasi. Namun, meskipun performa model cukup baik, masih terdapat beberapa tantangan yang perlu diatasi, seperti peningkatan akurasi dengan penggunaan dataset yang lebih besar dan metode balancing data yang lebih optimal. Oleh karena itu, penelitian lanjutan diperlukan untuk menyempurnakan model dan mengevaluasi kinerjanya dalam skenario medis yang lebih kompleks.

Saran

Dalam pelaksanaan penelitian yang telah dilakukan, diperoleh hasil yang dapat dijadikan bahan masukan atau saran bagi penyempurnaan penelitian ini maupun penelitian yang akan datang yaitu:

1. Penggunaan teknik balancing data yang lebih lanjut, seperti Synthetic Minority Over-sampling Technique (SMOTE), dapat membantu mengatasi ketidakseimbangan dataset tanpa meningkatkan risiko overfitting akibat augmentasi berlebihan.
2. Evaluasi model menggunakan interpretabilitas berbasis heatmap seperti Grad-CAM dapat memberikan wawasan lebih dalam mengenai bagian gambar MRI yang berkontribusi terhadap keputusan model, sehingga dapat digunakan sebagai alat bantu dalam diagnosis medis.

DAFTAR PUSTAKA

- Didi Susianto, 2015, Implementasi Dan Analisis Jaringan Menggunakan Wireshark, Cain And Abels, Network Minner. Jurnal CENDIKIA, Vol. XVI Oktober 2018 ISSN 2622-6782.
- Resi Utami Putri dan Jazi Eko Istiyanto, 2012, Analisis Forensik Jaringan Studi Kasus Serangan SQL Injection pada Server Universitas Gadjah Mada. IJCCS , Vol.6, No.2, July 2012, ISSN: 1978-1520
- Sinuraya dan Heryco Bremana P Tarigan, 2019, Sistem Monitoring Jaringan Wifi Menggunakan Wireshark Pada Stmik Kni Kristen Neuman Indonesia. Jurnal UPPM STMIK Kristen Neuman Indonesia Juli 2019 p-ISSN : 2548-5997, e-ISSN : 2687-1768.
- Tempo.co. (2025). Pengertian Klasifikasi Beserta Tujuan dan Contohnya. Diakses dari <https://www.tempo.co/digital/pengertian-klasifikasi-beserta-tujuan-dan-contohnya-1183221>
- Ahmadi, R., & Supriyono. 2016. *Metode Analisis Data dalam Penelitian*. Jakarta: Pustaka Ilmu.
- American Brain Tumor Association. 2020. *Understanding Brain Tumors: A Comprehensive Guide*. Chicago: ABTA Publications.
- Bishop, C. M. 2020. *Pattern Recognition and Machine Learning*. New York: Springer.
- Brown, P. D., et al. 2021. *Brain Tumor Diagnosis and Treatment Strategies*. Cambridge: Cambridge University Press.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. *Deep Learning*. Cambridge: MIT Press.
- He, K., Zhang, X., Ren, S., & Sun, J. 2021. *Deep Residual Learning for Image Recognition*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 87(5), 77-92.
- Krizhevsky, A., Sutskever, I., & Hinton, G. 2012. *ImageNet Classification with Deep Convolutional Neural Networks*. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
- Resi Utami Putri & Jazi Eko Istiyanto. 2012. Analisis Forensik Jaringan Studi Kasus Serangan SQL Injection pada Server Universitas Gadjah Mada. *IJCCS*, Vol. 6, No. 2, July 2012, ISSN: 1978-1520.
- Simonyan, K., & Zisserman, A. 2014. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. *arXiv preprint arXiv:1409.1556*.
- Sinuraya & Heryco Bremana P. Tarigan. 2019. Sistem Monitoring Jaringan Wifi Menggunakan Wireshark pada STMIK KNI Kristen Neuman Indonesia. *Jurnal UPPM STMIK Kristen Neuman Indonesia*, Juli 2019, p-ISSN: 2548-5997, e-ISSN: 2687-1768.
- Smith, J. D., et al. 2020. *Neuroscience and Oncology: Advances in Brain Tumor Research*. London: Oxford University Press.
- Sugiyono. 2019. *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*. Bandung: Alfabeta.
- Vasudevan, H., et al. 2019. *Deep Learning for Medical Image Analysis: Applications and Challenges*. *IEEE Transactions on Medical Imaging*, 38(4), 1-12.
- Wedianto, R. 2016. *Teknik Analisis Data dalam Ilmu Sosial*. Yogyakarta: Graha Ilmu.
- Zhang, Y. 2021. *Optimization Techniques for Deep Learning Models*. Springer.