

Transfer Learning model *Convolutional Neural Network* menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI

Dany Candra F¹, Gunawan Wibisono², Maulida Ayu F³, Mahazam Afrad⁴

^{1,2,3}*Fakultas Informatika, Institut Teknologi Telkom Purwokerto*

⁴*Fakultas Teknik dan Sains, Universitas Muhammadiyah Purwokerto*

*Corresponding Author: danycandra@ittelkom-pwt.ac.id

Abstract

Magnetic Resonance Imaging (MRI) is a digital imaging technique that is vital in detecting brain tumors. Early detection of brain tumors is the main focus in the medical field, helping to determine the potential malignancy of the tumor from the beginning. With the development of technology, deep learning has been widely applied, especially in the field of medical imaging. Convolutional Neural Network (CNN) is one of the deep learning techniques commonly used to classify images in MRI. The development of CNN through pre-trained models is an interesting research topic because it has the potential to improve the performance of models in various image processing tasks. This study focuses on one of the pre-trained CNN models, namely VGG 16. VGG-16 is a CNN with 16 convolutional layers, the deeper the convolutional layer, the better the classification results. The results of the study show that VGG-16 can achieve a prediction accuracy rate of up to 97%, providing positive hope in improving the effectiveness of diagnosis and treatment of brain tumors through the application of advanced technologies such as deep learning.

Keywords: CNN; Deep Learning; MRI; Brain Tumor; VGG-16

Abstrak

Magnetic Resonance Imaging (MRI) adalah suatu teknik pencitraan digital dalam mendeteksi adanya tumor otak. Pentingnya deteksi dini tumor otak menjadi fokus utama dalam bidang medis. Pendeteksian tumor sejak dini membantu menentukan potensi keganasan tumor tersebut sejak awal. Seiring berkembangnya teknologi, *deep learning* telah diterapkan secara luas, terutama dalam bidang pencitraan medis. *Convolutional Neural Network* (CNN) menjadi salah satu teknik *deep learning* yang umum digunakan untuk mengklasifikasikan citra pada MRI. Pengembangan CNN melalui model *pre-trained* menjadi topik penelitian yang menarik karena memiliki potensi untuk meningkatkan kinerja model pada berbagai tugas pengolahan citra. Penelitian ini berfokus pada salah satu model *pre-trained* CNN yaitu VGG 16. VGG-16 merupakan CNN dengan 16 lapisan konvolusi, semakin dalam lapisan konvolusi akan meningkatkan hasil klasifikasi. Hasil penelitian menunjukkan bahwa VGG-16 dapat mencapai tingkat akurasi prediksi hingga 97%, memberikan harapan positif dalam meningkatkan keefektifan diagnosis dan penanganan penyakit tumor otak melalui penerapan teknologi canggih seperti *deep learning*.

Kata Kunci: CNN; *Deep Learning*; MRI; Tumor Otak; VGG-16

I. INTRODUCTION

Tumor otak merupakan masalah kesehatan global yang memengaruhi berbagai kelompok usia, dari anak-anak hingga orang dewasa. Gejala dan prognosisnya bervariasi luas tergantung pada jenis tumor, lokasi, ukuran, serta faktor genetik dan lingkungan yang mempengaruhi perkembangan penyakit ini. Pasien

yang menderita tumor otak dapat mengalami berbagai gejala, seperti sakit kepala yang kronis, gangguan penglihatan, kehilangan koordinasi, perubahan perilaku, dan bahkan kehilangan kesadaran.

Jumlah individu yang terkena tumor otak telah mengalami peningkatan selama satu dekade terakhir di beberapa negara. Di Amerika dan Eropa, insidensi tumor otak meningkat dari 17.6/100.000 sampai 22.0/100.000 populasi dimana sekitar 18.500 kasus baru tumor otak primer didiagnosis tiap tahun di Amerika dan kasus tersebut memiliki angka kematian yang cukup tinggi sebesar 3% untuk 5 tahun *survival rate* [1]. Identifikasi penyakit ini sangat penting dalam upaya pencegahan perkembangan yang lebih parah. Salah satu kunci utama dalam diagnosis tumor otak adalah penerapan teknologi pencitraan medis. MRI menjadi salah satu alat pencitraan yang sangat diandalkan oleh para profesional medis untuk mengidentifikasi adanya tumor otak. Keunggulan utama MRI adalah penggunaannya yang sangat umum dalam diagnosis tumor otak, yang juga dikenal karena tidak menggunakan radiasi ionisasi [2].

Tumor otak biasanya terbagi menjadi tumor kanker dan non-kanker. Tumor non-kanker kerap disebut tumor jinak biasanya tumbuh secara bertahap dan terisolasi di otak dan tidak berdampak pada sel tubuh lainnya. Penanganan sejak dini dengan tepat terhadap tumor jinak memiliki kemungkinan besar masih dapat diobati dan dicegah agar tidak menjadi tumor kanker atau tumor ganas. Tumor ganas memiliki peluang lebih kecil untuk dapat diobati [3].

Menurut *World Health Organization* (WHO), diagnosis yang akurat untuk tumor otak adalah tindakan seperti deteksi tumor, identifikasi lokasi tumor, serta klasifikasi tumor. Dalam konteks ini, metode yang melibatkan pemanfaatan *Magnetic Resonance Imaging* (MRI) menjadi kunci. Proses diagnosis tumor otak menggunakan MRI melibatkan tahapan pendeteksian tumor, pengklasifikasian tumor berdasarkan derajat dan jenisnya, serta identifikasi lokasi tumor.

Perkembangan *Artificial Intelligence* (AI) pada era sekarang sudah merambah ke berbagai disiplin ilmu, termasuk bidang kesehatan. Salah satu sub-bidang ilmu AI adalah *deep learning*, dimana bidang ini memungkinkan komputer untuk melakukan pembelajaran dari data yang tersedia sehingga mampu untuk menghasilkan sebuah prediksi sesuai dengan data yang dipelajari. CNN merupakan salah satu teknik *deep learning* yang dapat diterapkan diberbagai jenis data, baik data berupa citra, suara, text dan sebagainya. Keunggulan lain dari CNN adalah model yang telah dihasilkan dapat dilatih ulang dan dilakukan tuning sesuai dengan data yang digunakan. CNN juga telah diimplementasikan untuk melakukan deteksi tumor otak dari data citra MRI [4].

CNN adalah metode berbasis jaringan saraf yang bertujuan untuk memproses data yang memiliki struktur grid. Konvolusi merupakan operasi utama dalam CNN. Proses konvolusi dasarnya adalah operasi aljabar linier yang mengalikan matriks filter dengan citra yang akan diproses. *Convolution layer* adalah lapisan utama yang paling penting untuk digunakan. Jenis *layer* lain yang umum digunakan adalah *pooling layer*, yaitu lapisan yang digunakan untuk mengambil nilai maksimum atau nilai rata-rata bagian piksel citra. CNN memiliki kemampuan untuk mempelajari fitur-fitur rumit dengan membentuk *feature map*. *Filter* dalam *convolution layer* melakukan *scanning* pada citra input untuk menghasilkan beberapa *feature map*. *Feature* terdeteksi dari citra masukan yang diwakili oleh kotak kecil di *feature map*. *Feature* ini diteruskan ke lapisan *max-pooling*, yang mempertahankan *feature* yang relevan dan membuang sisanya. *Feature* kemudian oleh lapisan *max-pooling* diubah menjadi vektor satu dimensi di lapisan *fully connected layer*, yang kemudian digunakan untuk menghitung probabilitas output atau hasil [5].

Pengembangan CNN melalui model *pre-trained* menjadi topik penelitian yang menarik karena memiliki potensi untuk meningkatkan kinerja model pada berbagai tugas pengolahan citra. VGG-16 merupakan salah satu model *pre-trained* yang dapat digunakan untuk implementasi *deep learning* dalam bidang citra. VGG-16 adalah model CNN yang dibuat oleh Visual Grup Geometri (VGG). Model ini dikemukakan oleh K. Simonyan dan A. Zisserman dari Universitas Oxford Tujuan utama VGG adalah merancang model dengan mempertimbangkan pengaturan kedalaman lapisan yang sesuai tanpa meningkatkan kompleksitas jaringan [3]. Artikel ini bertujuan untuk mengeksplorasi kesenjangan antara CNN biasa dan model *pre-trained*, dengan fokus pada VGG-16. Penelitian ini bertujuan untuk menginvestigasi efektifitas penggunaan model *deep learning* dengan model *pre-trained* VGG-16 dalam melakukan klasifikasi citra otak hasil MRI.

II. LITERATURE REVIEW

Terdapat beberapa penelitian tentang deteksi tumor otak, Febrianto et al. [2] melakukan deteksi tumor otak menggunakan CNN. Citra yang digunakan merupakan citra hasil MRI yang dibagi menjadi dua kelas yaitu: citra otak yang memiliki tumor dan citra otak yang tidak memiliki tumor. Proses augmentasi

digunakan untuk meningkatkan varian jumlah data sebelum dilakukan proses pembelajaran. Penelitian ini membandingkan CNN dengan 1 lapisan konvolusi dan 2 lapisan konvolusi. Matriks yang digunakan untuk melakukan pengukuran hasil klasifikasi adalah akurasi dan *f1-score*. Hasil akurasi yang didapat mencapai 93% pada CNN dengan 2 lapisan konvolusi.

Asiri et al. [6] melakukan deteksi otak yang mengandung tumor menggunakan teknik deep learning. Dalam penelitian ini arsitektur CNN dilakukan tuning menggunakan *pre-trained* model ResNet50. Model ini berfungsi melakukan ekstraksi fitur untuk identifikasi tumor otak. Bagian dasar dari model ResNet50 berfungsi untuk memahami ciri-ciri dalam gambar yang relevan dalam konteks deteksi tumor otak. Namun, untuk tujuan khusus dalam deteksi dan klasifikasi tumor otak, beberapa bagian akhir dari model ResNet50 telah digantikan oleh serangkaian lapisan baru yang sepenuhnya disesuaikan dengan tugas tersebut.

Pengembangan CNN melalui model pre-trained menjadi topik penelitian yang menarik karena memiliki potensi untuk meningkatkan kinerja model pada berbagai tugas pengolahan citra. Terdapat berbagai model pre-trained lain selain ResNet 50 yang dilakukan pada penelitian [6]. VGG 16 merupakan alternatif model pre-trained yang dapat digunakan untuk implementasi deep learning dalam bidang citra. VGG-16 adalah model CNN yang dibuat oleh *Visual Grup Geometri (VGG)*. Model ini dikemukakan oleh K. Simonyan dan A. Zisserman dari Universitas Oxford Tujuan utama VGG adalah merancang model dengan mempertimbangkan pengaturan kedalaman lapisan yang sesuai tanpa meningkatkan kompleksitas jaringan[7].

Penelitian terkait citra otak menggunakan VGG sebelumnya pernah dilakukan untuk melakukan klasifikasi penderita demensia. Penelitian melakukan klasifikasi terhadap empat jenis penyakit demensia dilihat dari citra otak hasil MRI yaitu, non-dementia, very mild dementia, mild dementia, and moderate dementia. Pembagian dataset pada penelitian ini adalah 80:20, 80% untuk data latih dan 20% untuk data uji. Skenario percobaan diuji dengan beberapa matriks evaluasi antara lain *accuracy, precision, recall* dan *f1-score*[8].

Artikel ini bertujuan untuk mengeksplorasi kesenjangan antara CNN biasa dan model *pre-trained*, dengan fokus pada arsitektur VGG-16. Penelitian ini bertujuan untuk menginvestigasi efektifitas penggunaan model *deep learning* dengan model *pre-trained* VGG-16 dalam melakukan klasifikasi citra otak hasil MRI. Metode ini dianggap relevan dan penting dalam menganalisis gambaran struktural otak secara otomatis, yang dapat mendukung diagnosis dan perawatan penyakit neurologis. Arsitektur VGG-16 telah terbukti memiliki kemampuan ekstraksi fitur yang kuat, terutama setelah pelatihan pada dataset yang besar[9]. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi positif terhadap pengembangan sistem diagnostik yang lebih presisi dan cepat dalam konteks medis, membuka peluang baru untuk pemahaman mendalam terkait kondisi kesehatan otak yang kompleks.

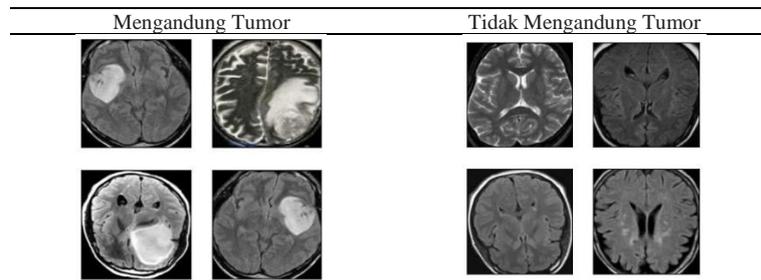
II. RESEARCH METHOD

A. Alat dan Bahan Penelitian

Alat yang digunakan untuk melakukan percobaan pada penelitian ini adalah virtual komputer dari *Google Colaboratory*. Bahasa pemrograman *Python v3* untuk menulis kode program percobaan. *Tensorflow v2* merupakan *library* yang digunakan sebagai alat bantu dalam menulis arsitektur *neural network* yang dibuat dalam penelitian ini.

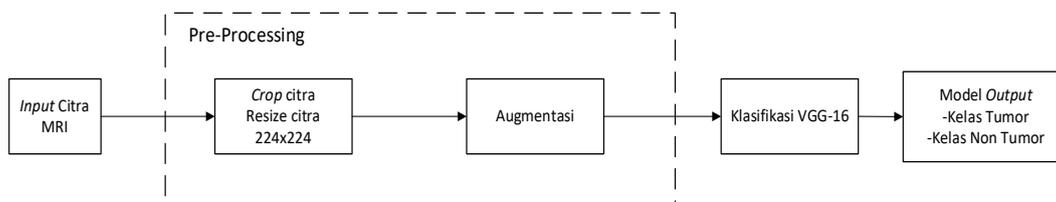
Bahan yang digunakan dalam penelitian ini adalah dataset *Brain MRI Images for Brain Tumor Detection* yang diperoleh dari kaggle.com. Dataset ini terdiri dari 253 gambar otak hasil MRI yang dikelompokkan menjadi 2 kelompok, 155 gambar otak yang memiliki tumor, dan 98 gambar otak yang tidak memiliki tumor. Tabel I menunjukkan sampel citra MRI dalam dataset.

TABEL I
SAMPEL CITRA PADA DATASET



B. Tahapan Penelitian

Penelitian ini berfokus pada klasifikasi tumor otak dari citra MRI menggunakan arsitektur VGG 16. Gambar 1 menunjukkan diagram blok sistem yang diteliti. Sistem yang dibangun dalam penelitian ini dibagi menjadi 2 tahap yaitu, tahap *pre-processing* dan tahap klasifikasi menggunakan arsitektur VGG-16. *Pre-processing* terbagi menjadi dua tahap yaitu, penyesuaian ukuran citra (*resize*) dan augmentasi. Klasifikasi dilakukan setelah proses *pre-processing* sehingga menghasilkan model yang dapat melakukan klasifikasi menjadi dua kelas yaitu, tumor dan non tumor.



Gambar 1. Diagram Blok Penelitian

1) *Pre-Processing Citra*

Pre-processing citra masukan dilakukan pertama kali dengan melakukan pemangkasan bagian tepi citra agar mengurangi bagian yang tidak mengandung citra otak, sebelum pemangkasan ditentukan tepi maksimalnya agar pada saat hasil pemangkasan, objek pada gambar tetap utuh. *Resize* citra dilakukan karena ukuran citra pada dataset mempunyai ukuran yang berbeda-beda.

2) *Augmentasi*

Jumlah data dalam dataset tidak cukup untuk digunakan sebagai data pelatihan CNN. Oleh karena itu metode augmentasi digunakan untuk mengatasi permasalahan ketimpangan tersebut. Augmentasi merupakan algoritma yang dapat memanfaatkan informasi data statistik dan membentuk model yang terintegrasi. Algoritma ini dapat menghasilkan sejumlah gambar dua dimensi dengan berbagai pose dan ukuran. Penerapan augmentasi untuk memperoleh varian citra dapat meningkatkan akurasi segmentasi CNN[10].

3) *Arsitektur VGG-16*

VGG-16 terdiri dari 16 lapisan konvolusi dan fully connected, memungkinkan model ini untuk mengekstraksi fitur-fitur yang sangat abstrak dari gambar. Desain VGG-16 ditandai oleh kekonsistenan dalam penggunaan lapisan konvolusi dengan *filter* kecil berukuran 3x3 dan lapisan *max-pooling* 2x2. Dengan merinci arsitektur menjadi beberapa blok konvolusi berturut-turut, VGG-16 mencapai tingkat kedalaman tanpa menambahkan kompleksitas yang berlebihan. Desain ini memungkinkan model untuk secara efektif menangkap fitur dalam gambar, mulai dari fitur rendah seperti tepi hingga fitur tingkat tinggi yang lebih kompleks[7].

Penelitian ini akan melakukan *fine tuning* untuk menyesuaikan arsitektur VGG 16 dengan data yang digunakan. Penambahan lapisan *flatten* yang berguna untuk mengubah hasil ekstraksi fitur yang masih

berbentuk *multidimensional array* agar bisa digunakan sebagai *input* untuk *lapisan fully-connected*. Lapisan *dropout* digunakan agar mengurangi jumlah *neuron* pada saat pelatihan dengan tujuan mencegah terjadinya *overfitting* karena jumlah neuron yang terlalu banyak. Proses akhir adalah menambahkan lapisan *fully connected*. Lapisan *Fully-Connected* adalah lapisan di mana semua neuron aktivasi yang menghubungkan *output flatten* dengan neuron di lapisan selanjutnya seperti halnya jaringan saraf tiruan biasa. Fungsi aktivasi yang digunakan dalam penelitian ini adalah *sigmoid* dan menggunakan optimasi Adam. Susunan arsitektur model yang digunakan pada penelitian ini terdapat pada Tabel II.

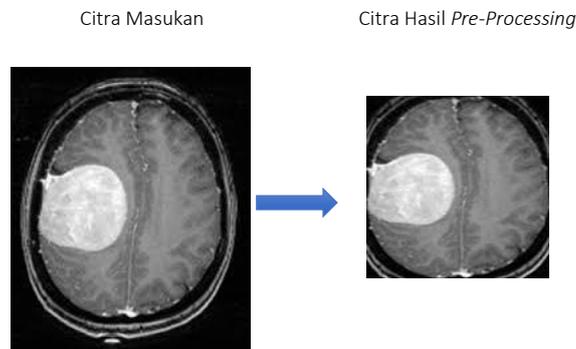
TABEL II
ARSITEKTUR VGG 16

Layer	Output Shape	Kernel Size	Stride	# of Filters
Input	(224, 224, 3)	-	-	-
Conv1_1	(224, 224, 64)	3x3	1	64
Conv1_2	(224, 224, 64)	3x3	1	64
Pool1	(112, 112, 64)	2x2	2	-
Conv2_1	(112, 112, 128)	3x3	1	128
Conv2_2	(112, 112, 128)	3x3	1	128
Pool2	(56, 56, 128)	2x2	2	-
Conv3_1	(56, 56, 256)	3x3	1	256
Conv3_2	(56, 56, 256)	3x3	1	256
Conv3_3	(56, 56, 256)	3x3	1	256
Pool3	(28, 28, 256)	2x2	2	-
Conv4_1	(28, 28, 512)	3x3	1	512
Conv4_2	(28, 28, 512)	3x3	1	512
Conv4_3	(28, 28, 512)	3x3	1	512
Pool4	(14, 14, 512)	2x2	2	-
Conv5_1	(14, 14, 512)	3x3	1	512
Conv5_2	(14, 14, 512)	3x3	1	512
Conv5_3	(14, 14, 512)	3x3	1	512
Pool5	(7, 7, 512)	2x2	2	-
Flatten	(4096)	-	-	-
Dropout	(256)	-	-	-
FC	(256)	-	-	-
Output				2

IV. RESULTS AND DISCUSSION

Tahap pertama dalam percobaan penelitian ini adalah *pre-processing*. *Pre-processing* dilakukan untuk memperlancar proses pelatihan yang karena ada berbagai varian intensitas, kontras, dan ukuran dalam citra [11]. Citra input akan menjadi pre-process pertama yaitu proses pemangkasan. Proses pemangkasan adalah proses dimana pemangkasan citra yang tidak mengandung unsur otak. Setelah melakukan pemangkasan, citra diubah ukuran menjadi (240, 240, 3) = (*image_width*, *image_height*, *channel*) karena citra dalam dataset memiliki ukuran yang berbeda. Angka 3 pada masing-masing ukuran melambangkan channel dari warna citra yaitu *red*, *green* dan *blue* (RGB). Gambar 2 merupakan contoh proses perubahan

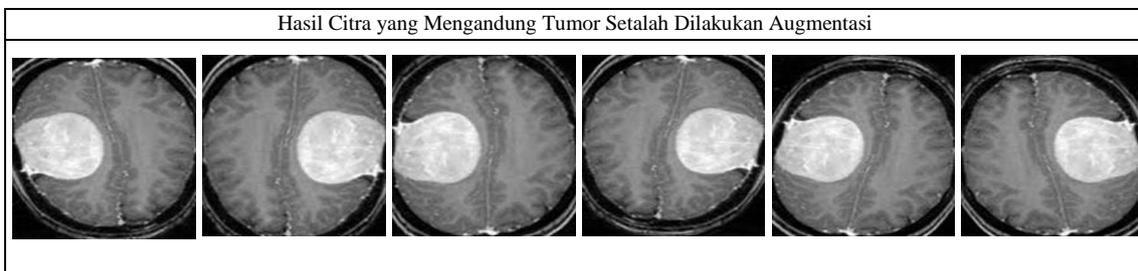
dari citra masukan pada saat tahap *pre-processing*. Ukuran 224 x 224 x 3 merupakan ukuran *default* yang menjadi masukan pada arsitektur VGG 16.



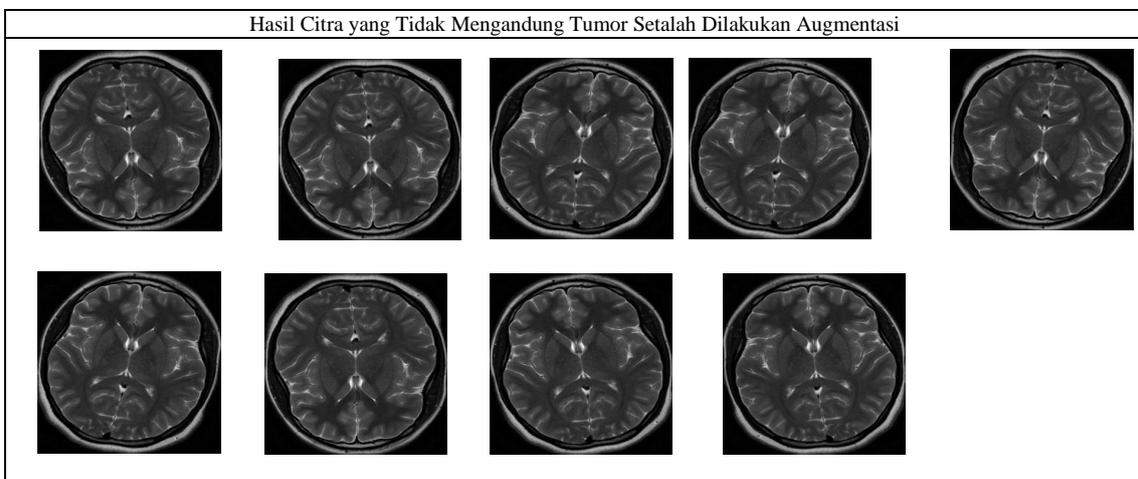
Gambar 2. Tahap Pre-Processing Citra

Tahap kedua setelah *pre-processing* adalah augmentasi. Tujuan augmentasi dalam penelitian ini adalah menambah jumlah data untuk meningkatkan varian data [9]. Setiap citra yang memiliki tumor diaugmentasi menjadi 6 citra, dan citra tanpa tumor augmentasi menjadi 9 citra. Setelah dilakukan augmentasi data, dataset terdiri dari 1085 sampel mengandung tumor (53%) dan 980 sampel tidak mengandung tumor (47%), sehingga total terdapat 2065 citra. Tabel III merupakan contoh hasil augmentasi citra yang mengandung tumor, sedangkan Tabel IV merupakan contoh hasil augmentasi citra yang tidak mengandung tumor. Citra dilakukan augmentasi dengan cara melakukan rotasi dan membalik citra.

TABEL III
CONTOH HASIL AUGMENTASI CITRA MENGANDUNG TUMOR



TABEL IV
CONTOH HASIL AUGMENTASI CITRA TIDAK MENGANDUNG TUMOR



Percobaan dalam penelitian ini dilakukan pada 2065 citra yang terdiri dari 1085 citra yang mengandung tumor dan 980 citra yang tidak mengandung tumor. Data selanjutnya dibagi menjadi 70% sebagai data pelatihan, 15% sebagai data validasi dan 15% sebagai data uji. Data dilakukan percobaan menggunakan parameter 15 epoch dan 64 batch. Hasil pelatihan kemudian dievaluasi menggunakan matriks akurasi dan *f1-score*. Akurasi dihitung dengan mencari nilai *true positif*, *true negatif*, *false positif*, dan *false negatif* antara kelas dan hasil prediksi dari kedua model[8]. *F1 score* adalah suatu metrik evaluasi yang digunakan untuk mengukur performa dari suatu model klasifikasi, terutama pada kasus ketidakseimbangan kelas (*class imbalance*) di dalam dataset. Metrik ini menggabungkan *precision* dan *recall*, memberikan gambaran holistik tentang seberapa baik model mampu mengidentifikasi dan memisahkan antara kelas positif dan negatif. Presisi adalah rasio dari jumlah positif yang diklasifikasikan dengan benar terhadap total data yang diklasifikasikan sebagai positif. *Recall*, di sisi lain, adalah rasio dari jumlah data positif yang diklasifikasikan dengan benar terhadap total jumlah data positif yang seharusnya terdeteksi[12]. *F1 score* dihitung dengan menggunakan rumus:

$$Akurasi = \frac{(tp + tn)}{(tp + tn + fp + fn)} \quad (1)$$

$$F1\ Score = \frac{2 \times Presisi \times Recall}{Presisi + Recall} \quad (2)$$

dimana

$$Presisi = \frac{(tp)}{(t + fp)} \quad (3)$$

$$Recall = \frac{(tp)}{(tp + fn)} \quad (4)$$

Hasil percobaan kemudian akan dibandingkan dengan penelitian [2] [6]. Perbandingan dilakukan untuk mengetahui kinerja dari beberapa arsitektur CNN. Perbandingan dilakukan dengan dataset, ukuran citra dan matrik evaluasi yang sama. Matrik evaluasi yang digunakan adalah akurasi dan *F1 Score* semakin tinggi nilai yang dihasilkan maka akan semakin baik hasil klasifikasi yang dihasilkan oleh model. Tabel V menunjukkan hasil percobaan yang dilakukan dalam penelitian ini. Pelatihan pertama [2] CNN menggunakan 2 lapisan konvolusi. Nilai akurasi adalah 93% dan *F1 Score* 92%. Penelitian kedua [6] menggunakan ResNet 50 untuk memiliki nilai akurasi sebesar 94% dan F1-Score sebesar 92%. Penelitian menggunakan VGG-16 dalam penelitian ini menghasilkan nilai akurasi 97% dan F1-Score 96%. Proses pelatihan dalam penelitian ini memerlukan waktu kurang lebih 68 detik pada setiap epoch yang dikerjakan atau sekitar 17 menit pada 15 *epoch*. Waktu yang diperlukan untuk pengujian adalah sekitar 3 detik, proses ini sudah termasuk tahap *pre-processing* dan proses prediksi oleh model VGG 16 yang dihasilkan.

TABEL V
HASIL EVALUASI MODEL

Model CNN	Akurasi	F1-Score
CNN 2 Layer [2]	93%	92%
ResNet 50 [6]	94%	92%
VGG -16 (penelitian ini)	97%	96%

V. Conclusion

Penelitian terbaru menunjukkan bahwa penggunaan model *pre-trained* VGG-16 berbasis CNN efektif dalam mendiagnosis tumor otak melalui analisis gambar MRI. Model ini mencapai tingkat akurasi sebesar 97% dan *F1-Score* sebesar 96%, yang menunjukkan tingkat keandalan yang tinggi dalam klasifikasi tumor mempengaruhi hasil evaluasi. Metode augmentasi yang digunakan dalam pelatihan model dapat memperkaya variasi data, mengurangi kemungkinan ketidakseimbangan kelas, dan meningkatkan performa model. Selain itu, penambahan lapisan konvolusi dapat meningkatkan akurasi, meskipun memerlukan waktu pelatihan yang lebih lama. Penelitian selanjutnya, disarankan untuk menggunakan lebih banyak gambar guna meningkatkan keberagaman dataset dan kualitas klasifikasi. Selain itu, penelitian dapat diperluas untuk mengklasifikasikan berbagai jenis tumor otak. Dengan demikian, penelitian selanjutnya diharapkan dapat meningkatkan ketepatan dan ketangguhan sistem dalam deteksi dini tumor otak.

REFERENCES

- [1] Kementerian Kesehatan, “KEPUTUSAN MENTERI KESEHATAN REPUBLIK INDONESIA NOMOR HK.01.07/MENKES/397/2020 PEDOMAN NASIONAL PELAYANAN KEDOKTERAN TATA LAKSANA TUMOR OTAK,” *Kementerian kesehatan Republik Indonesia, Komite Penanggulangan Kanker Nasional*, vol. 14, no. 2. Jakarta, pp. 1–4, 2020.
- [2] H. A. N. Dany Candra, Indah Soesanti, “Convolutional Neural Network for Brain Tumor Detection using MRI,” *Cogn. Syst. Res.*, 2019.
- [3] S. Somasundaram and R. Gobinath, “Current Trends on Deep Learning Models for Brain Tumor Segmentation and Detection - A Review,” *Proc. Int. Conf. Mach. Learn. Big Data, Cloud Parallel Comput. Trends, Perspectives Prospect. Com. 2019*, pp. 217–221, 2019.
- [4] M. W. Nadeem *et al.*, “Brain tumor analysis empowered with deep learning: A review, taxonomy, and future challenges,” *Brain Sci.*, vol. 10, no. 2, pp. 1–33, 2020.
- [5] D. I. Swasono, M. A. R. Wijaya, and M. A. Hidayat, “Klasifikasi Penyakit pada Citra Buah Jeruk Menggunakan Convolutional Neural Networks (CNN) dengan Arsitektur Alexnet,” *INFORMAL Informatics J.*, vol. 8, no. 1, p. 68, 2023.
- [6] A. A. Asiri *et al.*, “Brain Tumor Detection and Classification Using Fine-Tuned CNN with ResNet50 and U-Net Model : A Study on TCGA-LGG and TCIA Dataset for MRI Applications,” 2023.
- [7] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” pp. 1–14, 2014.
- [8] A. Bagaskara and M. Suryanegara, “Evaluation of VGG-16 and VGG-19 Deep Learning Architecture for Classifying Dementia People,” *Proc. - 2021 4th Int. Conf. Comput. Informatics Eng. IT-Based Digit. Ind. Innov. Welf. Soc. IC2IE 2021*, pp. 1–4, 2021.
- [9] Y. Li and K. Deng, “Breast Cancer Identification Study Using Improved VGG,” *2023 8th Int. Conf. Cloud Comput. Big Data Anal. ICCCBDA 2023*, pp. 467–470, 2023.
- [10] Z. Tang, K. Chen, M. Pan, M. Wang, and Z. Song, “An augmentation strategy for medical image processing based on Statistical Shape Model and 3D Thin Plate Spline for deep learning,” *IEEE Access*, vol. 7, pp. 1–1, 2019.
- [11] T. Zhou and S. Ruan, “A review: Deep learning for medical image segmentation using multi-modality fusion.”
- [12] D. Chicco and G. Jurman, “The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation,” pp. 1–13, 2020.