

Klasifikasi Tumor Otak Menggunakan *Convolutional Neural Network*

Haidar Fakhri¹, Setiawardhana², Tessa Badriyah³, Iwan Syarif⁴, Riyanto Sigit⁵
^{1, 2, 3, 4, 5} Politeknik Elektronika Negeri Surabaya,
Jl. Raya ITS - Kampus PENS Sukolilo, Surabaya, Indonesia
E-mail: haidar.fakhri.16@gmail.com¹, setia@eepis-its.edu², tessa@pens.ac.id³,
iwanarif@yahoo.com⁴, riyanto@pens.ac.id⁵

Abstract - Brain tumors have various types, depending on the position of the brain tumor, which are broadly categorized into 3 types, namely Glioma, Meningioma and Pituitary. To detect brain tumors, Magnetic Resonance Imaging (MRI) is used, which produces images of brain tumors. This research has produced tools that can be used to help classify brain tumor types, so that health staff do not only rely on clinical medical experience as a consideration in providing a quick and accurate diagnosis. The brain MRI image classification method used in this research is Deep Learning Convolutional Neural Network (CNN) with 2 architectural scheme models. The dataset used contains MRI images of the human brain with a total of 7023 images, with details of 1621 Glioma, 1645 Meningioma, 1757 Pituitary, and 2000 Notumor. F1-Score evaluation of the scheme 1 and scheme 2 models respectively: 96% and 98%, while the Accuracy values are 98% and 99%. This shows that the F1-Score and Accuracy Values of scheme 2 model are better. The accuracy results of this research are higher compared to several previous studies, namely from [1], [2], [3], [5], [7], and [8], respectively: 94.39%, 97.54%, 97.18 %, 96.08%, 96.36%, and 95.55%.

Keywords - Brain Tumor, Deep Learning, Convolutional Neural Network, Classification, Accuracy.

Intisari - Tumor otak memiliki beragam tipe, tergantung pada posisi tumor otak tersebut, yang secara garis besar dikategorikan menjadi 3 tipe yakni Glioma, Meningioma, dan Pituitary. Untuk mendeteksi tumor otak digunakan *Magnetic Resonance Imaging* (MRI) yang menghasilkan citra tumor otak. Penelitian yang dilakukan ini menghasilkan alat bantu (*tools*) yang dapat digunakan untuk membantu klasifikasi tipe tumor otak, sehingga staf kesehatan tidak hanya mengandalkan pengalaman klinis kedokteran sebagai bahan pertimbangan dalam memberikan diagnosis secara cepat dan akurat. Metode klasifikasi citra MRI otak yang digunakan pada penelitian ini adalah *Deep Learning Convolutional Neural Network* (CNN) dengan 2 model skema arsitektur. Dataset yang digunakan memuat citra MRI otak manusia dengan total 7023 citra, dengan rincian 1621 Glioma, 1645 Meningioma, 1757 Pituitary, dan 2000 Notumor. Evaluasi *F1-Score* model skema 1 dan skema 2 berturut-turut: 96% dan 98%, sedangkan nilai *Accuracy* 98% dan 99%. Hal ini menunjukkan bahwa Nilai *F1-Score* dan *Accuracy*, model skema 2 lebih baik. Hasil *accuracy* penelitian ini lebih tinggi dibandingkan dengan beberapa penelitian sebelumnya, yakni dari [1], [2], [3], [5], [7], dan [8], berturut-turut: 94.39%, 97.54%, 97.18%, 96.08%, 96,36%, dan 95.55%.

Kata Kunci – Tumor Otak, *Deep Learning*, *Convolutional Neural Network*, Klasifikasi, *Accuracy*.

I. PENDAHULUAN

Tumor otak mungkin saja terjadi pada individu manapun, pada usia berapapun, dan muncul diarea mana saja serta memiliki beragam bentuk dan ukuran. Menurut laporan resmi yang diterbitkan oleh WHO kanker otak menyumbang kurang dari 2% dibanding jenis kanker yang lain, namun morbiditas parah dan komplikasi yang dihasilkan sangat besar [1]. Perusahaan riset kanker di Inggris menyebutkan bahwa ada sekitar 5.250 kematian yang diakibatkan karena otak [2].

Pada umumnya tumor otak dapat diklasifikasikan menjadi dua jenis yaitu tumor jinak dan ganas. Tumor jinak adalah tumor yang mampu menyebarkan dan mempengaruhi jaringan otak sehat lainnya karena tumor ini cenderung memiliki struktur homogen dan tidak mengandung sel-sel penyakit lainnya, sedangkan tumor ganas cenderung memiliki struktur heterogen dan mengandung sel-sel ganas yang biasanya tumbuh di luar otak dan disebut kanker otak. Glioma adalah jenis tumor yang tumbuh di jaringan glia dan sumsum tulang belakang, sedangkan Meningioma adalah jenis tumor yang tumbuh pada membran yang melindungi otak dan sumsum tulang belakang.

Penyebab Glioma antara lain: yang paling banyak adalah faktor usia (45 - 65 tahun), terkena paparan terapi radiasi, dan sangat jarang untuk faktor keturunan. Dampak Glioma antara lain: sakit kepala pada pagi hari, gejala mual dan muntah, menurunnya fungsi otak dalam berpikir dan mengolah informasi, kehilangan ingatan, gampang emosi, penglihatan kabur dan gagap.

Penyebab Meningioma antara lain: Terapi radiasi yang melibatkan kepala, hormon perempuan, kondisi sistem saraf turunan dan kegemukan. Dampak Meningioma antara lain yaitu menurunnya fungsi penglihatan, pendengaran, penciuman dan ingatan, sakit kepala yang parah di pagi hari, kejang-kejang, kelemahan di kaki dan tangan, dan mengalami masalah berbicara.

Penyebab Pituitary antara lain adalah faktor genetic yang langka. Lingkungan dan gaya hidup tampaknya tidak berpengaruh. Dampak Pituitary antara lain: sakit kepala, permasalahan mata yang disebabkan oleh tekanan pada saraf optic, rasa sakit di wajah, kelopak mata terkulai, kejang-kejang, dan gejala mual dan muntah.

Dari semua penjabaran diatas sangat penting kiranya dilakukan deteksi awal pada pasien yang terjangkit. Langkah pertama yang dapat dilakukan adalah melakukan segmentasi citra otak pasien. Segmentasi citra otak memberikan informasi yang krusial bagi dokter untuk penanganan dan evaluasi tindak lanjut. Segmentasi secara manual cenderung membutuhkan waktu yang lama sehingga dibutuhkan segmentasi otomatis untuk menindak lanjuti permasalahan tersebut [1]. Berbagai cara telah dilakukan untuk mendeteksi dini penyakit tumor otak dan *Magnetic Resonance Imaging (MRI) Scan* yang lebih cocok untuk mendeteksi penyakit tumor otak [3]. Ahli radiologi menggunakan *MRI Scan* untuk mendiagnosis kondisi organ (otak) dalam (tumor otak) yang beragam.

Machine Learning (ML) adalah sebuah metode yang membentuk dasar dari banyak sistem analisis citra medis yang tersedia secara komersial. ML telah menunjukkan keberhasilan besar dalam mempelajari pola kompleks yang memungkinkan komputer untuk membuat prediksi terhadap data yang tidak teramati[4].

Deep Learning (DL) merupakan sub bagian dari ML[6] yang fokus pada pengembangan sebuah sistem yang mampu belajar sendiri tanpa harus berulang kali di program secara manual oleh manusia. Dalam beberapa tahun terakhir terdapat perkembangan pesat dalam penelitian dibidang *Deep Learning*, termasuk mempopulerkannya dibidang *Computer Vision (CV)*. Komponen utama dari DL adalah *Layered Hierarchical Data Representation* yang biasanya berbentuk jaringan saraf dengan lebih dari dua lapisan, metode tersebut memungkinkan *Data Synthesis* secara otomatis dari tingkat fitur yang lebih tinggi berdasarkan yang lebih rendah.

Convolutional Neural Network (CNN) merupakan salah satu algoritma DL yang digunakan untuk analisa dan klasifikasi data citra digital. CNN juga merupakan arsitektur DL yang terinspirasi oleh mekanisme persepsi visual alami dari makhluk hidup. CNN sangat populer karena kemampuannya dalam merepresentasikan objek gambar dan mempelajari suatu objek citra, serta CNN dapat mempelajari banyak representasi dari data. CNN telah menunjukkan kegunaannya dalam berbagai tugas *Computer Vision* seperti *Object Recognition, Human Activity Recognition, Facial Recognition*, dan kebanyakan aplikasi

dalam hal pencitraan medis. CNN adalah pilihan algoritma terbaik untuk tugas *Image Classification*. Dalam CNN, tidak diperlukan untuk mengumpulkan fitur citra secara manual karena CNN memiliki kemampuan untuk menghasilkan fitur dengan sendirinya. CNN adalah jaringan saraf yang dalam dengan *Image Input Layer*, *2D Convolution Layer*, *ReLU Layer*, *Pooling Layer*, *Fully Connected Layer*, *Softmax Layer*, dan *Classification Layer*. Efektivitas CNN tergantung pada struktur lapisan ini serta parameter pada *Convolutional Layer*. Hal ini dapat menjadi salah satu solusi yang dapat mempercepat proses penanganan dini pada pasien yang terjangkit tumor otak dan dapat membantu ahli medis dalam mendiagnosa tumor otak yang diderita pasien.

Pada penelitian ini, *Deep Learning* dengan CNN diajukan untuk mengklasifikasikan tiga tipe citra MRI tumor otak yang sering ditemui yaitu Glioma, Meningioma, Pituitary, dan juga citra MRI otak yang sehat. Dataset yang digunakan diambil dari <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> yang memuat citra MRI otak dengan total 7023 citra, dengan rincian 1621 citra tipe Glioma, 1645 citra untuk tipe Meningioma, 1757 citra untuk tipe Pituitary, dan 2000 citra untuk otak yang sehat.

Untuk mendapatkan nilai *F1-Score* dan *Accuracy* yang lebih tinggi dari penelitian sebelumnya, maka pada penelitian ini dibangun arsitektur model CNN dengan 2 (dua) model skema, yakni skema 1 dan skema 2. Upaya lain selain arsitektur CNN, yakni meningkatkan jumlah dataset. Pada penelitian ini, jumlah dataset-nya lebih banyak dibandingkan penelitian sebelumnya yaitu: 7023 citra. Sedangkan jumlah dataset pada penelitian sebelumnya yaitu: 3064 citra [1], 3064 citra [2], 2406 [3], 253 [5], 3064 citra [7], dan 253 [8].

II. SIGNIFIKANSI STUDI

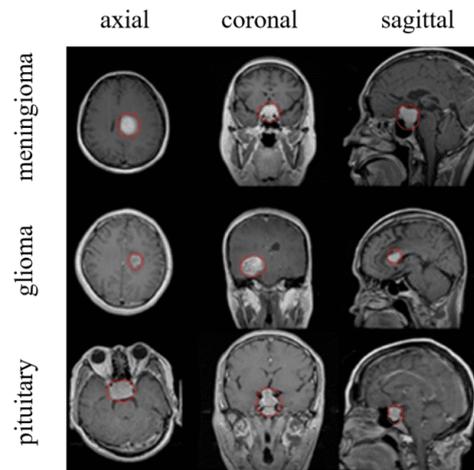
A. Otak Dan Tumor Otak

Otak adalah organ kompleks yang mengontrol pikiran, ingatan, emosi, sentuhan, keterampilan motorik, penglihatan, pernapasan, suhu, rasa lapar dan setiap proses yang mengatur tubuh manusia. Otak mengirim dan menerima sinyal kimia dan listrik ke seluruh tubuh. Sinyal yang berbeda mengontrol proses yang berbeda, dan otak bertugas untuk menafsirkan-nya. Misalnya, beberapa sinyal membuat tubuh merasa lelah, sementara yang lain membuat tubuh merasa sakit. Beberapa pesan disimpan di dalam otak, sementara pesan lainnya disampaikan melalui tulang belakang dan melintasi jaringan saraf tubuh yang luas hingga ke ekstremitas yang jauh. Untuk melakukan hal ini, sistem saraf pusat bergantung pada miliaran neuron (sel saraf) yang berada pada tubuh.

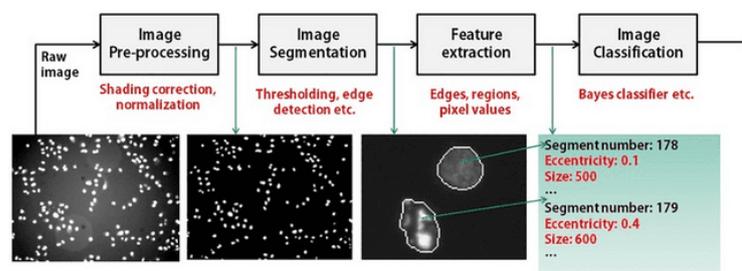
Tumor otak adalah pertumbuhan sel-sel di dalam atau di dekat otak. Tumor otak bisa terjadi di jaringan otak. Tumor otak juga bisa terjadi di dekat jaringan otak. Beberapa lokasi pada organ otak yang berpotensi terkena tumor otak antara lain jaringan saraf dalam otak (Glioma), kelenjar pituitary (Pituitary), dan selaput yang menutupi permukaan otak (Meningioma). Tumor otak mempunyai potensi untuk bermula di otak. Kasus ini disebut juga dengan tumor otak primer. Terkadang, kanker dapat juga untuk menyebar ke otak dari bagian tubuh lain-nya yang terjangkit kanker sebelumnya. Tumor ini adalah tumor otak sekunder, disebut juga tumor otak metastatik.

B. Image Processing

Image Processing digunakan untuk meningkatkan kualitas data gambar dengan menghindari distorsi yang tidak diinginkan. Gambar medis otak MRI bersifat lebih sensitif dibandingkan gambar medis lainnya. Citra tersebut perlu mengandung level kebisingan/*noise* seminimal mungkin sehingga sangat informatif untuk diagnosa tumor otak yang lebih akurat dan mengandung *error* seminimal mungkin.



Gambar 1. Contoh Data Citra MRI Tumor Otak



Gambar 2. Image Processing

1. Image Classification

Di antara masalah *Computer Vision*, klasifikasi gambar menonjol karena perannya yang tak tergantikan dalam teknologi modern. Ini melibatkan pemberian label atau tag ke seluruh gambar berdasarkan data pelatihan yang sudah ada sebelumnya dari gambar yang sudah diberi label. Meskipun prosesnya tampak sederhana pada pandangan pertama, proses ini sebenarnya memerlukan analisis gambar tingkat piksel untuk menentukan label yang paling tepat untuk keseluruhan gambar. Hal ini memberikan data dan *insight* yang berharga, sehingga memungkinkan pengambilan keputusan yang tepat dan hasil yang dapat ditindaklanjuti.

Sudah menjadi fakta umum bahwa gambar yang dilihat secara keseluruhan terdiri dari ratusan hingga ribuan piksel kecil. Sebelum *Computer Vision* dapat menentukan dan memberi label pada gambar secara keseluruhan, sistem perlu menganalisis masing-masing komponen gambar untuk membuat asumsi yang tepat. Itulah sebabnya teknik klasifikasi gambar menganalisis gambar tertentu dalam bentuk piksel dan melakukannya dengan memperlakukan gambar sebagai array matriks, yang ukurannya ditentukan oleh resolusi gambar. Piksel gambar digital diambil dan dikelompokkan ke dalam apa yang kita kenal sebagai “*class*”.

2. Image Pre-processing

Pemrosesan data gambar adalah salah satu masalah yang paling banyak dieksplorasi dalam komunitas ilmu data. Setiap pengembang memiliki cara unik untuk melakukannya. Beberapa alat dan platform yang digunakan dalam prapemrosesan gambar antara lain Python, OpenCV, Keras, Tensorflow, dan lainnya.

Saat membangun project Machine Learning / Computer Vision, satu hal yang selalu di perlukan adalah data. Dalam project yang bersangkutan, jenis data yang akan digunakan adalah data citra MRI tumor otak. Namun, beberapa masalah yang sering berkaitan dengan data

gambar mencakup kompleksitas, inaccuracies, dan data yang tidak sempurna. Inilah sebabnya sebelum membangun model Machine Learning, data harus diproses terlebih dahulu (dibersihkan dan diproses ke format yang diinginkan) untuk mencapai hasil yang diinginkan. Tahap/hal ini cukup penting dikarenakan tahapan ini berpengaruh dalam meningkatkan akurasi model, menghilangkan data yang cacat, serta untuk mengurangi kompleksitas yang tidak diperlukan.

Ada beberapa teknik yang digunakan untuk melakukan preprocessing data gambar. Contohnya meliputi; mengubah ukuran/nilai piksel gambar (Normalization), mengubah gambar menjadi skala abu-abu (Greyscale), dan meng-augmentasi data/gambar. Grayscale hanyalah mengubah gambar dari berwarna menjadi hitam putih. Biasanya digunakan untuk mengurangi kompleksitas komputasi dalam algoritma pembelajaran mesin. Karena sebagian besar gambar tidak memerlukan warna untuk dikenali, sebaiknya gunakan skala abu-abu, yang akan mengurangi jumlah piksel dalam gambar, sehingga mengurangi komputasi yang diperlukan.

Normalisasi biasanya diterapkan untuk mengubah nilai piksel gambar menjadi nilai yang umum atau lebih familiar. Normalisasi juga disebut sebagai penskalaan ulang data, ini adalah proses memproyeksikan piksel data gambar (intensitas) ke rentang yang telah ditentukan (biasanya (0,1) atau (-1, 1)). Ini biasanya digunakan pada format data yang berbeda, dan ingin menormalkan semuanya untuk menerapkan algoritma yang sama pada format tersebut.

Manfaat dari normalisasi antara lain adalah menciptakan keadilan di semua gambar - misalnya, menskalakan semua gambar ke rentang yang sama yaitu [0,1] atau [-1,1] memungkinkan semua gambar berkontribusi sama terhadap total kerugian dibandingkan saat gambar lain memiliki rentang piksel tinggi dan rendah, kerugian kuat dan kerugian lemah. Manfaat lainnya dari metode normalisasi ialah untuk memberikan kecepatan pembelajaran standar - Karena gambar berpiksel tinggi memerlukan kecepatan pembelajaran rendah dan gambar piksel rendah memiliki kecepatan pembelajaran tinggi, penskalaan ulang membantu memberikan kecepatan pembelajaran standar untuk semua gambar.

C. *Machine Learning* (ML) dan *Deep Learning* (DL)

ML adalah seni pemrograman dari komputer yang dimana ia dapat belajar dari data. Menurut Arthur Samuel (1959), *Machine Learning* adalah pembelajaran yang memberi komputer perintah untuk belajar dari data tanpa dilakukan sesuatu hal terperinci untuk harus mengikuti instruksi yang diprogram (Boehmke & Greenwell, 2019).

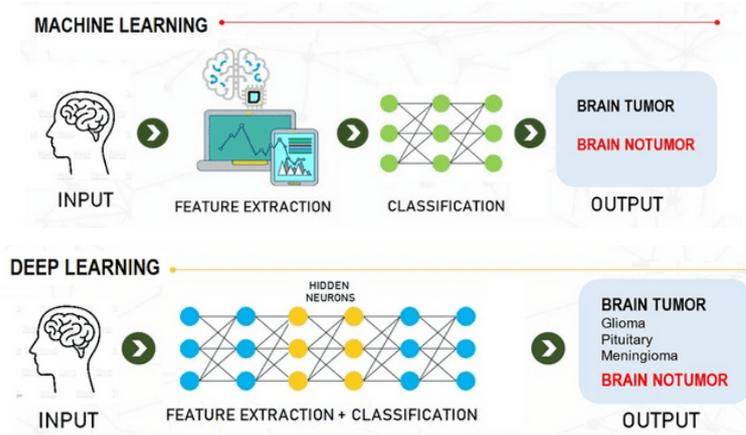
Tujuan dari ML adalah untuk melatih mesin berdasarkan data dan algoritma yang diberikan. Menggunakan data dan informasi yang kemudian diproses mesin belajar bagaimana membuat keputusan. ML bersifat dinamis, yang artinya memiliki kemampuan untuk mengubah dirinya sendiri saat diterapkan ke data yang lebih banyak. Aspek pembelajaran dari *Machine Learning* berarti bahwa algoritma ML berusaha meminimalkan kesalahan dan memaksimalkan kemungkinan prediksi menjadi benar [10].

DL adalah subdivisi dari ML yang didasarkan pada pembelajaran representasi data dan pembelajaran fitur hierarkis. Algoritma *Deep Learning* memanfaatkan *Multilayer Array* identitas pemrosesan nonlinier untuk ekstraksi fitur. Output dari setiap lapisan sekuensial adalah input dari yang berikutnya, dan itu membantu dalam abstraksi data saat kita memasuki jauh ke dalam jaringan.

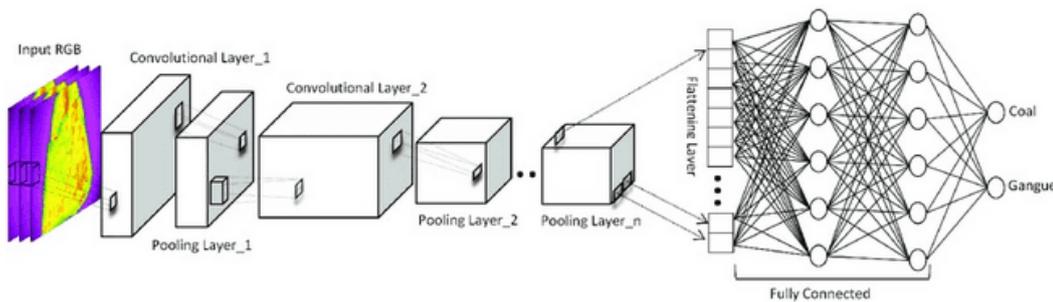
D. *Convolutional Neural Network* (CNN)

CNN adalah jenis khusus dari *Artificial Neural Network* (ANN) yang menggunakan operasi matematika (*algorithm*) yang disebut konvolusi sebagai pengganti perkalian matriks umum di setidaknya satu lapisannya. Algoritma ini adalah pengenalan yang efektif diterapkan dalam pola pengenalan dan pengolahan citra. CNN ini mensimulasikan jaringan saraf biologis melalui jaringan bobot bersama struktur. CNN secara luas dipraktikkan di bidang komputer

dalam masalah *Computer Vision*. Ini terdiri dari properti parameter berbagi yang mengurangi jumlah parameter yang dibutuhkan untuk model dibandingkan dengan ANN. Selain itu, kualitas fitur yang diekstraksi oleh CNN sangat memenuhi standar yang telah ada. Dalam model *Convolutional Neural Network* ini saya menerapkan serangkaian operasi *Convolution* + *Pooling*, disertai dengan *Fully Connected Layer*.



Gambar 3. Machine Learning dan Deep Learning



Gambar 4. Convolutional Neural Network – Multi Layer

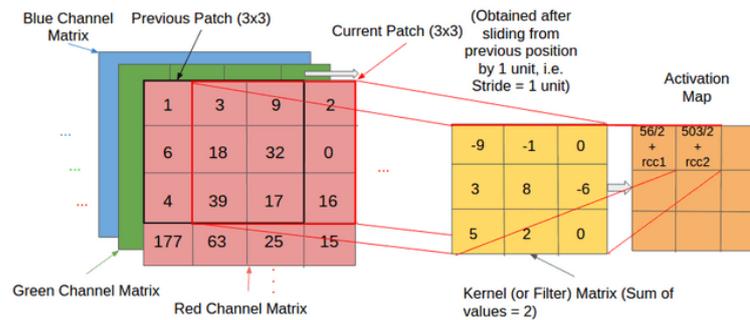
1. Convolution

Tahapan ini merupakan kunci dari semua algoritma komputer. Convolution merupakan proses pengambilan matriks kecil angka yang disebut kernel kemudian akan melewati gambar dan akan mengubah berdasarkan nilai-nilai dari kernel dengan rumus sebagai berikut:

$$G[m, n] = (f * h)[m, n] \sum_j \sum_k h[j, k] f[m - j, n - k] \tag{1}$$

dimana nilai kernel dilambangkan oleh f dan h sedangkan indeks baris dan kolom dari matriks hasil ditandai dengan m dan n.

Dalam CNN, inputnya adalah tensor dengan bentuk: (jumlah input) × (tinggi input) × (lebar input) × (saluran input). Setelah melewati lapisan konvolusi, gambar menjadi abstrak ke peta fitur, juga disebut peta aktivasi, dengan bentuk: (jumlah input) × (tinggi peta fitur) × (lebar peta fitur) × (saluran peta fitur).



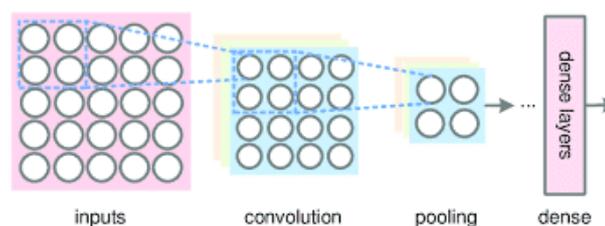
Gambar 5. Konsep Konvolusi

Lapisan *Convolution* menggolong input dan meneruskan hasilnya ke lapisan berikutnya. Proses ini mirip dengan respons neuron di korteks visual terhadap stimulus tertentu. Setiap konvolusi neuron memproses data hanya untuk bidang reseptifnya. Meskipun jaringan saraf *feedforward* yang terhubung sepenuhnya dapat digunakan untuk mempelajari fitur dan mengklasifikasikan data, arsitektur ini umumnya tidak praktis untuk input yang lebih besar seperti gambar resolusi tinggi. Ini akan membutuhkan jumlah neuron yang sangat tinggi, bahkan dalam arsitektur *shallow*, karena ukuran input gambar yang besar, di mana setiap piksel adalah fitur input yang relevan.

2. *Pooling*

Lapisan konvolusi dapat mencakup lapisan *Pooling* lokal dan / atau global bersama dengan lapisan konvolusi tradisional. Lapisan *Pooling* mengurangi dimensi data dengan menggabungkan output dari cluster neuron pada satu lapisan menjadi satu neuron pada lapisan berikutnya. Penggabungan lokal menggabungkan kelompok kecil, ukuran ubin seperti 2×2 biasanya digunakan. Penyatuan global bekerja pada semua neuron dari peta fitur.

Ada dua jenis pooling yang umum digunakan: *Max* dan *Average*. *Max pooling* menggunakan nilai maksimum dari setiap cluster lokal neuron pada feature map, sedangkan *Average pooling* mengambil nilai rata-rata.



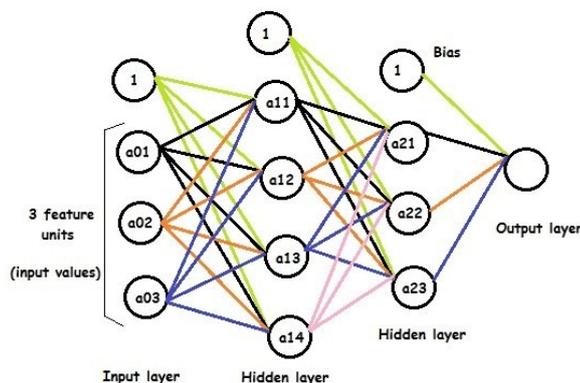
Gambar 6. Konsep *Pooling*

3. *Fully Connected Layer*

Fully Connected Layer menghubungkan setiap neuron dalam satu lapisan ke setiap neuron di lapisan lain. Ini sama dengan jaringan neuron *Multilayer Perceptron* (MLP) tradisional. Matriks yang diratakan melewati *Fully Connected Layer* untuk mengklasifikasikan gambar.

Setiap neuron dalam jaringan saraf menghitung nilai output dengan menerapkan fungsi tertentu ke nilai input yang diterima dari bidang reseptif di lapisan sebelumnya. Fungsi yang diterapkan pada nilai input ditentukan oleh vektor bobot (*weight*) dan bias. Pembelajaran terdiri dari penyesuaian bias dan bobot ini secara iteratif.

Vektor bobot dan bias disebut filter dan mewakili fitur tertentu dari input (misalnya, bentuk tertentu). Fitur yang membedakan CNN adalah bahwa banyak neuron dapat berbagi filter yang sama. Ini mengurangi jejak memori karena bias tunggal dan satu vektor bobot digunakan di semua bidang reseptif yang berbagi filter itu, sebagai lawan dari setiap bidang reseptif yang memiliki bias dan bobot vektornya sendiri.



Gambar 7. Konsep *Fully Connected Layer*

E. Evaluasi Metrik

Saat mengevaluasi model ML, kita tidak boleh terlalu longgar. Evaluasi perlu dipahami dengan jelas jenis metrik serta model ML dan menyadari kelebihan dan kekurangan dari setiap metrik yang digunakan. Meskipun kebanyakan biasanya menggunakan metrik akurasi/precisi 98% atau bahkan 99%, pernyataan ini bisa sangat menyesatkan tanpa konteks lebih lanjut. Untuk seseorang yang hanya diberikan metrik ini tanpa konteks apa pun, masalahnya mungkin sulit dideteksi. Oleh karena itu, perlu digunakan beberapa jenis metrik selain dari metrik utama untuk mengevaluasi model ML dengan baik.

Confusion Matrix adalah sebuah tabel yang menggambarkan kinerja model klasifikasi (output berupa fitur / kelas dua atau lebih). Matriks ini umumnya sangat intuitif dan relatif mudah dipahami. Berikut tabel kebenaran dari *Confusion Matrix* seperti yang ditunjukkan pada tabel I berikut:

TABEL I
TABEL KEBENARAN CONFUSION MATRIX

		Nilai Prediksi	
		Positif	Negatif
Nilai Sebenarnya	Positif	True Positive (TP)	False Negative (FN)
	Negatif	False Positive (FP)	True Negative (TN)

Menafsirkan istilah *Confusion Matrix*:

- a. True Positive (TP): Ketika model memprediksi "1" dan data aktual juga "1".
- b. True Negative (TN): Ketika model memprediksi "0" dan data aktual juga "0".
- c. False Positive (FP): Ketika model memprediksi "1" dan data aktualnya "0".
- d. False Negative (FN): Ketika model memprediksi "0" dan data aktualnya "1".

Model yang sempurna adalah model yang memiliki 0 *False Positive* dan 0 *False Negatives*, tetapi pada kenyataannya tidak mungkin. Saat menilai hasil prediksi, tidak ada rencana tindakan standar untuk diikuti tentang apa yang harus diminimalkan.

1. Akurasi

Dalam klasifikasi, akurasi merupakan indeks kualitas yang paling banyak digunakan. Akurasi didefinisikan sebagai rasio jumlah sampel yang diklasifikasi dengan benar terhadap jumlah total data. Hal tersebut dapat dilakukan menggunakan persamaan sebagai berikut:

$$Accuracy = \frac{\sum True\ Positive}{\sum True\ Positive + \sum False\ Positive} = \frac{\sum TP}{\sum TP + \sum FP} \quad (2)$$

2. Presisi

Presisi dapat didefinisikan sebagai nilai keakuratan yang didapatkan sistem dari keseluruhan data, sehingga akan dapat diketahui kelas apa yang diklasifikasikan dan sesuai atau tidak dengan kelas sebenarnya. Hal tersebut dapat dilakukan menggunakan persamaan sebagai berikut:

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \\ = \frac{TP}{TP + FP} \quad (3)$$

3. Recall

Recall dapat disebut sebagai tingkat keberhasilan suatu system dalam memprediksi suatu kategori. Hal tersebut dapat dilakukan menggunakan persamaan sebagai berikut:

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \\ = \frac{TP}{TP + FN} \quad (4)$$

4. F1 Score

Skor F1 adalah metrik yang menggabungkan *Precision* dan *Recall*. Kombinasi ini dibuat dengan menggunakan rata-rata Harmonik. Penggunaan mean Harmonic, membuat metrik skor F1 lebih masuk akal untuk perbedaan antara *Recall* dan *Precision*, membuatnya condong lebih dekat ke yang lebih kecil dari kedua angka tersebut. Beberapa masalah utama yang diangkat dalam penggunaan metrik ini adalah bahwa metrik ini memberikan relevansi yang sama dengan Presisi dan *Recall* (*False Positive* dan *False Negatives*). Pada kenyataannya, seperti yang disebutkan sebelumnya mungkin ada weight yang berbeda untuk kemungkinan kesalahan klasifikasi.

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \\ = 2 * \frac{PR * RCL}{PR + RCL} \quad (5)$$

F. Penelitian Terkait

Beberapa penelitian yang telah dilakukan sebelumnya tentang klasifikasi tumor otak dengan algorithm masing-masing seperti tertera pada tabel II berikut.

TABEL II
ALGORITHM BEBERAPA PENELITIAN TERKAIT

No.	Penelitian	Tahun	Algorithm
1.	Sunanda Das <i>et al.</i> [1]	2019	Convolutional Neural Network (CNN)
2.	Hossam H. Sultan <i>et al.</i> [2]	2019	Deep Learning (DL) Model based on CNN
3.	Yakub Bhanothu <i>et al.</i> [3]	2020	Faster R-CNN Architecture
4.	Chirodip Lodh Choudhury <i>et al.</i> [5]	2020	3-Layered CNN Architecture
5.	Wadhah Ayadi <i>et al.</i> [7]	2020	Custom CNN Architecture for Multi-Class
6.	Gajendra Raut <i>et al.</i> [8]	2020	CNN for Classification, Auto-Encoder for Compression & K-Means for Segmentation

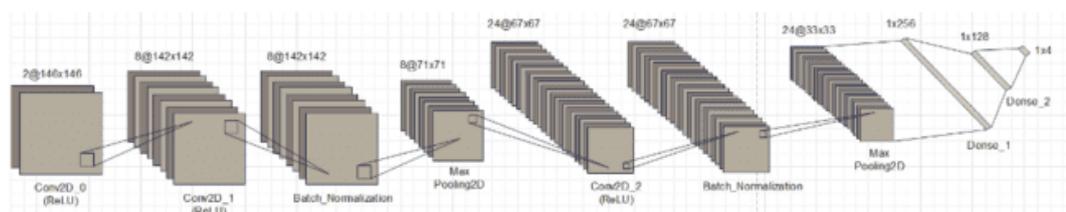
Nilai evaluasi metrik dan accuracy yang dihasilkan dari beberapa penelitian sebelumnya tersebut diperlihatkan pada tabel III.

TABEL III
NILAI EVALUASI METRIK DAN ACCURACY HASIL PENELITIAN SEBELUMNYA

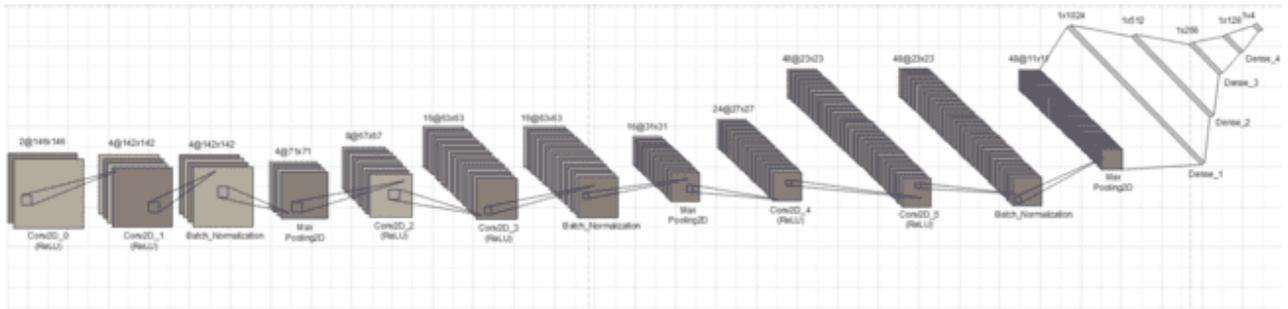
No.	Penelitian	Dataset	Precision	Recall	f1-score	Accuracy
1	Sunanda Das <i>et al.</i> [1]	- Meningioma (708), - Glioma (1426), - Pituitary (930).	93.33%	93%	93.33%	94.39%
2	Hossam H. Sultan <i>et al.</i> [2]	- Meningioma (708), - Glioma (1426), - Pituitary (930).	97.2%	95.5%	98.7%	97.54%
3	Yakub Bhanothu <i>et al.</i> [3]	- Glioma (805), - Meningioma (694), - Pituitary (907).	100%	96.15%	98.04%	97.18%
4	Chirodip Lodh Choudhury <i>et al.</i> [5]	- Tumorous, - Non-Tumorous.	0.9487	0.9863	0.9736	96.08%
5	Wadhah Ayadi <i>et al.</i> [7]	- Meningioma (708), - Pituitary (930), - Glioma (1426).	94,03	94,39	94,19	96,36%
6	Gajendra Raut <i>et al.</i> [8]	- Tumorous (155), - Non-Tumorous (98).	96%	96%	96%	95.55%

G. Build Model CNN

Pada tahapan ini dilakukan penentuan model CNN yang cocok untuk pengklasifikasian tumor otak dengan data yang telah tersedia. Terdapat dua alur kerja dari arsitektur CNN yang diusulkan yaitu skema 1 dan skema 2. Alur dari kedua skema tersebut dapat dilihat pada Gambar 8. dan Gambar 9.



Gambar 8. Model Skema 1 CNN



Gambar 9. Model Skema 2 CNN

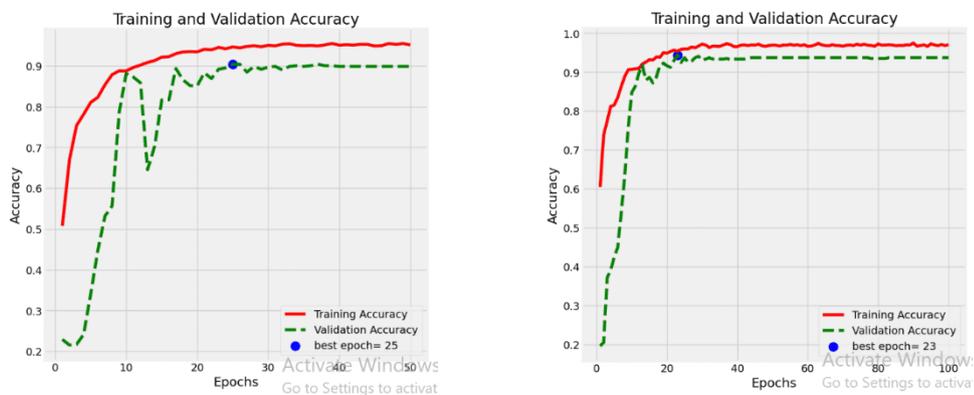
TABEL IV
PERBANDINGAN MODEL SKEMA 1 DAN SKEMA 2

Model Skema 1	Model Skema 2
Menggunakan arsitektur sequential	Menggunakan arsitektur sequential
Terdapat 2 max pooling layer	Terdapat 3 max pooling layer
Terdapat 2 hidden layer (dense)	Terdapat 4 hidden layer (dense)
Terdapat dropout layer	Terdapat dropout layer
Menggunakan adam optimizer	Menggunakan adam optimizer

III. HASIL DAN PEMBAHASAN

A. Hasil Model Skema 1

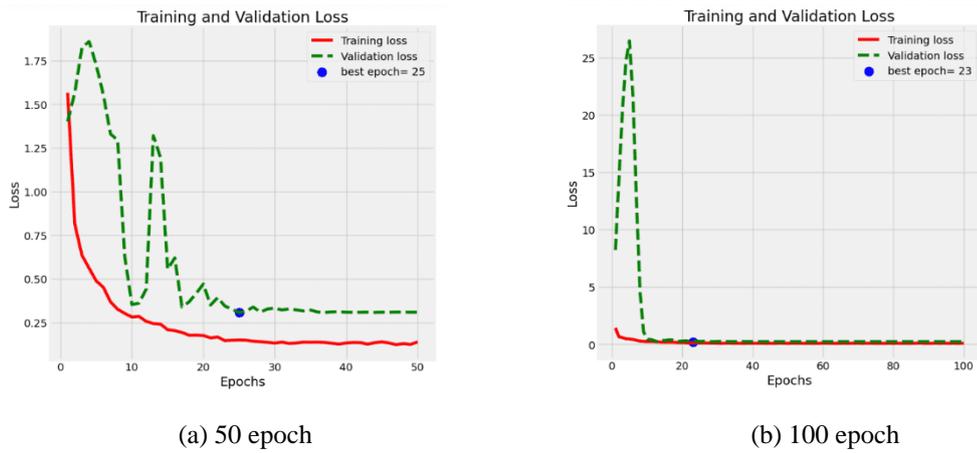
Secara garis besar pola grafik akurasi training dan validasi dan grafik loss training dan validasi tidak mengalami overfitting maupun underfitting, karena kedua garis tidak menyimpang terlalu jauh dan bersifat stabil.



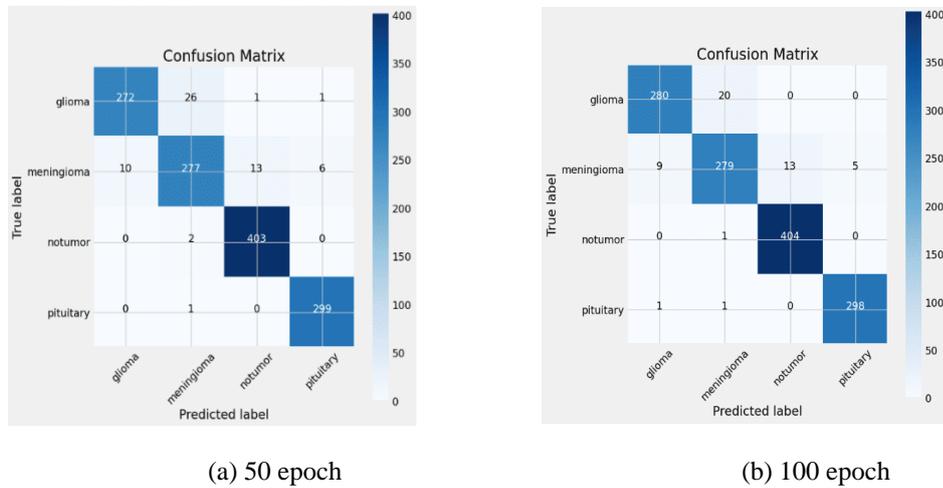
(a) 50 epoch

(b) 100 epoch

Gambar 10. Grafik Accuracy, Training dan Validasi



Gambar 11. Grafik Loss, Training dan Validasi



Gambar 12. Confusion Matrix Hasil Testing Data

TABEL V
INDEKS PERFORMANSI SKEMA 1 UNTUK 50 EPOCH

	Precision	Recall	f1-Score	Support
Glioma	0,9645	0,9067	0,9347	300
Meningioma	0,9052	0,9052	0,9052	306
Notumor	0,9664	0,9951	0,9805	405
Pituitary	0,9771	0,9967	0,9868	300
Accuracy			0,9771	1311
Macro avg	0,9533	0,9509	0,9518	1311
Weighted avg	0,9542	0,9542	0,9539	1311

TABEL VI
INDEKS PERFORMANSI SKEMA 1 UNTUK 100 EPOCH

	Precision	Recall	F1-Score	Support
Glioma	0,9656	0,9367	0,9509	300
Meningioma	0,9320	0,8954	0,9133	306
Notumor	0,9618	0,9951	0,9782	405

	Precision	Recall	F1-Score	Support
Pituitary	0,9772	1,0000	0,9885	300
Accuracy			0,9798	1311
Macro avg	0,9592	0,9568	0,9577	1311
Weighted avg	0,9592	0,9596	0,9592	1311

B. Hasil Terbaik Nilai Evaluasi Metrik Dan Accuracy

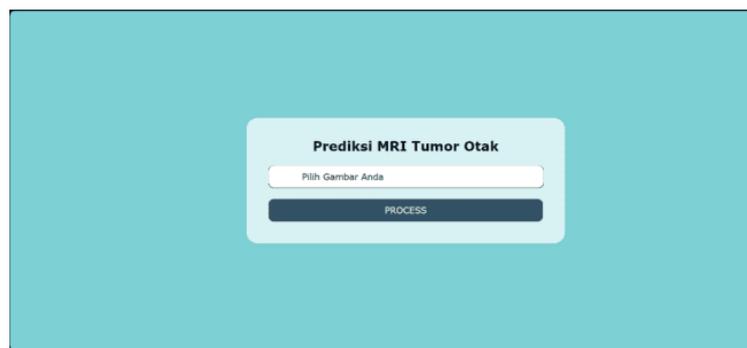
Berdasarkan percobaan yang telah dilakukan dengan skema 1 dan 2, didapat hasil rata-rata tertinggi seperti ditunjukkan pada tabel VII.

C. Membangun API (Application Programming Interface)

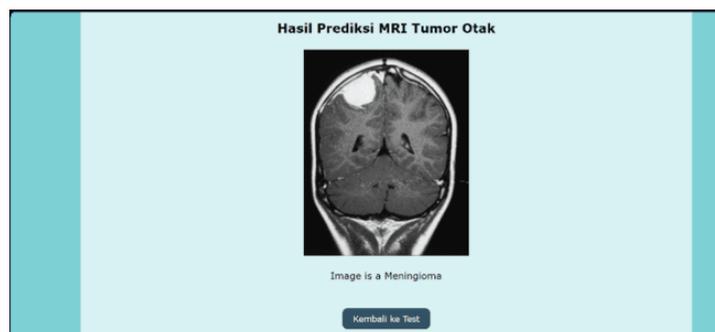
Aplikasi yang bisa dibuat dari penelitian ini salah satunya adalah sebagai alat bantu ahli medis dalam mempercepat proses penanganan dini pada pasien yang terjangkit tumor otak, dalam hal ini mendiagnosa tumor otak yang diderita pasien. Untuk keperluan tersebut, dalam penelitian ini dibuat API sederhana yang mampu mendiagnosa jenis tumor otak dari citra otak yang dihasilkan oleh MRI.

TABEL VII
HASIL INDEKS PERFORMANSI TERTINGGI

Skema	Performansi	Indeks	Epoch
1	Accuracy	0,9798	100
	Precision	0,9592	100
	Recall	0,9596	100
	f1-Score	0,9592	100
2	Accuracy	0,9886	50
	Precision	0,9771	50
	Recall	0,9771	50
	f1-Score	0,9770	50



Gambar 13. Tampilan Depan Untuk Memilih Citra Tumor Otak Yang Akan Diprediksi Jenis Tumornya



Gambar 14. Tampilan Hasil Prediksi Tumor Otak Meningioma

IV. KESIMPULAN

1. Pada penelitian ini didapatkan perbedaan yang sangat kecil nilai accuracy sebagai fungsi jumlah epoch dan/atau fungsi model skema yaitu antara 0,0030 - 0,0286 atau 0,30% – 2,93%. Dari hasil ini berarti bahwa dataset yang digunakan jumlahnya sudah cukup memadai dan datanya balance.
2. Pengujian dengan 10 Fold - Cross Validation menghasilkan standar deviasi yang kecil pada perhitungan precision, recall, f1-score & accuracy antara data original dan augmented, yaitu berkisar $\pm 0,03$. Hasil ini menunjukkan bahwa penyimpangan sebaran nilai precision, recall, f1-score & accuracy semakin mendekati nilai rata-ratanya.
3. Hasil nilai evaluasi metrik dan akurasi terbaik dari keseluruhan penelitian ini sesuai dengan yang diharapkan, meliputi Precision, Recall, F1-score dan Accuracy masing-masing: 0,9879; 0,9878; 0,9878; dan 0,9939, diperoleh dari skema 3, dengan data augmented, dan dengan epoch 100.
4. Hasil akurasi terbaik dari penelitian ini yaitu 98,86% masih lebih tinggi dibandingkan beberapa hasil penelitian sebelumnya yaitu dari Sunanda Das dkk. [1], Hossam H. Sultan dkk. [2], Yakub Bhanothu dkk. [3], Chirodip Lodh Choudhury dkk. [5], Wadhah Ayadi dkk. [7], Gajendra Raut dkk. [8], nilai akurasinya masing-masing adalah: 94,39%, 97,54%, 97,18%, 96,08%, 96,36%, dan 95,55%.
5. Aplikasi sederhana sebagai alat bantu ahli medis guna mempercepat proses penanganan dini pada pasien yang terjangkit tumor otak telah dibuat. Aplikasi ini mampu mendiagnosa jenis tumor otak dari citra otak yang dihasilkan oleh MRI dalam waktu kurang dari 3 detik.

REFERENSI

- [1] Sunanda Das, O.F.M. Riaz Rahman Aranya, Nishat Nayla Labiba, “*Brain Tumor Classification Using Convolutional Neural Network*”, Khulna University of Engineering & Technology, Bangladesh, 2019.
- [2] Hossam H. Sultan, Nancy M. Salem, Walid Al-Atabany, “*Multi-Classification of Brain Tumor Images Using Deep Neural Network*”, IEEE Access Volume 7, 2019.
- [3] Yakub Bhanothu, Anandhanarayanan Kamalakannan, Govindaraj Rajamanickam, “*Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network*”, 2020 6th International Conference on Advanced Computing & Communication Systems (ICACCS), India, 2020.
- [4] Fauzi, M., Teddyyana, A., & Enda, D. (2021). Pengembangan Aplikasi Mobile Tanggap Bencana Di Kab. Bengkalis Menggunakan Framework Flutter. ZONAsi: Jurnal Sistem Informasi, 3(1), 27-36.
- [5] Chirodip Lodh Choudhury, Chandrakata Mahanty, Raghvendra Kumar, Brojo Kishore Mishra, “*Brain Tumor Detection and Classification Using Convolutional Neural Network and Deep Neural Network*”, GIET University Gunupur, India, 2019.
- [6] Tedyyana, Agus, Osman Ghazali, and Onno Purbo. "Model Design of Intrusion Detection System on Web Server Using Machine Learning Based." Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023, September 21st, 2023, Bengkalis, Riau, Indonesia. 2024.
- [7] Wadhah Ayadi, Wadji Elhamzi, Mohamed Atri, “*A new deep CNN for brain tumor classification*”, 20th international conference on Sciences and Techniques of Automatic control & computer engineering (STA), Tunisia, 2020.
- [8] Gajendra Raut, Aditya Raut, Jeevan Bhagade, Jyoti Bhagade, Sachin Gavhane, “*Deep*

- Learning Approach for Brain Tumor Detection and Segmentation*”, 2020 IEEE International Conference on Convergence to Digital World – Quo Vadis (ICCDW 2020).
- [9] Diah Priyawati, Indah Soesanti, Indriana Hidayah, “*Kajian Pustaka Metode Segmentasi Citra Pada MRI Tumor Otak*”, Prosiding SNST (Seminar Nasional Sains dan Teknologi) ke-6 Tahun 2015, FT Universitas Wahid Hasyim Semarang.
- [10] Rachmad Andre R, Baghas Wahyu P, dan Rani Purbaningtyas, “*Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3*”, Jurnal Sistem Informasi, Teknologi Informasi dan Komputer, Universitas Muhammadiyah Jakarta, Vol. 11, No. 3, May 2021, pp. 55 – 59.
- [11] Hasnain Ali Shah, Faisal Saeed, Sangseok Yun, Jun-Hyun Park, Anand Paul, Jae-Mo Kang, “*A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet*”, Basic Science Research Program through the National Research Foundation of Korea (NRF), Korea, 2022.
- [12] Uswatun Hasanah, Riyanto Sigit, Tri Harsono, “*Classification of Brain Tumor on Magnetic Resonance Imaging Using Support Vector Machine*”, 2021 International Electronics Symposium (IES), Electronic Engineering Polytechnic Institute of Surabaya.
- [13] Annisa Wulandari, Riyanto Sigit, Mochamad Mobed Bachtiar, “*Brain Tumor Segmentation to Calculate Percentage Tumor Using MRI*”, 2018 International Electronics Symposium on Knowledge Creation and Intelligent Computing (IES-KCIC), Informatics and Computer Departement Electronic Engineering Polytechnic Institute of Surabaya.
- [14] Rizal Romadhoni Hidayatullah, Riyanto Sigit, Sigit Wasista, “*Segmentation of Head CT-Scan to Calculate Percentage of Brain Hemorrhage Volume*”, 2017 International Electronics Symposium on Knowledge Creation and Intelligent Computing (IES-KCIC), Informatics and Computer Departement Electronic Engineering Polytechnic Institute of Surabaya.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada seluruh dosen pengajar Prodi Teknik Komputer Politeknik Elektronika Negeri Surabaya (PENS) yang telah memberikan ilmunya selama perkuliahan, dan khususnya semua Dosen Pembimbing dan Penguji Proyek Akhir yang telah meluangkan waktu dalam proses pembimbingan dan evaluasinya.