

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK (CNN) DALAM KLASIFIKASI TUMOR OTAK MENGGUNAKAN CITRA MAGNETIC RESONANCE IMAGING (MRI)

Andhika Wira Sakti, Ahmad Fahrudi Setiawan, Nurlaily Vendyansyah

Teknik Informatika, Institut Teknologi Nasional Malang

Jalan Raya Karanglo km 2 Malang, Indonesia

2118104@scholar.itn.ac.id

ABSTRAK

Magnetic Resonance Imaging (MRI) berperan penting dalam diagnosis tumor otak. Namun, interpretasi manual citra *MRI* untuk diagnosis tumor otak sering kali menghadapi tantangan, seperti tingginya variabilitas antar radiolog dan potensi kesalahan diagnosis. Penelitian ini bertujuan mengimplementasikan *Convolutional Neural Network (CNN)* untuk klasifikasi tumor otak menggunakan citra *Magnetic Resonance Imaging (MRI)*, dengan fokus pada pengembangan model berbasis *website* yang efisien. Metode yang digunakan meliputi *pra-pemrosesan data (resize, normalisasi pixel, augmentasi)*, *ekstraksi fitur menggunakan CNN*, modifikasi model (penambahan *flatten layer, ReLU*, dan *softmax*), kompilasi, pelatihan, evaluasi, dan pengujian model. Dataset yang digunakan terdiri dari 3 kelas: *no tumor, glioma*, dan *meningioma*. Hasil pengujian *blackbox* menunjukkan sistem berfungsi optimal pada berbagai *browser*. Pengujian model menunjukkan akurasi keseluruhan 93,3%, *sensitivitas* rata-rata 96,7%, dan *spesifisitas* rata-rata 97,2%. Penelitian ini diharapkan dapat berkontribusi pada pengembangan sistem otomatis diagnosis tumor otak, meningkatkan efisiensi dan akurasi.

Kata kunci: *Convolutional Neural Network, Klasifikasi, Magnetic Resonance Imaging, Tumor Otak*

1. PENDAHULUAN

Perkembangan teknologi di bidang kesehatan, khususnya radiologi, telah meningkatkan akurasi dalam diagnosis dan penanganan berbagai penyakit, termasuk tumor otak, yaitu pertumbuhan sel abnormal di otak yang dapat bersifat jinak maupun ganas. Deteksi dini dan klasifikasi yang tepat sangat penting untuk menentukan strategi pengobatan dan meningkatkan prognosis pasien. Di Indonesia, sekitar 300 kasus tumor otak dilaporkan setiap tahunnya [1]. Dr. Achmad Zamroni dari RSUD Soesodoro Djatikusumo melalui program SAPA mengimbau masyarakat untuk mewaspadaikan faktor risiko seperti paparan radiasi, riwayat keluarga, penurunan imunitas, usia lanjut, serta pola hidup tidak sehat.

Magnetic Resonance Imaging (MRI) merupakan metode pencitraan yang banyak digunakan dalam deteksi tumor otak karena kemampuannya dalam menampilkan detail jaringan lunak lebih baik dibandingkan *CT scan* [2]. Namun, proses interpretasi citra *MRI* sangat bergantung pada keahlian radiolog, sehingga rentan terhadap variabilitas dan kesalahan manusia [3].

Untuk mengatasi keterbatasan tersebut, pendekatan berbasis kecerdasan buatan seperti *Convolutional Neural Network (CNN)* telah dikembangkan. *CNN* merupakan arsitektur *deep learning* yang dirancang khusus untuk pengolahan citra melalui tahapan konvolusi, pooling, dan klasifikasi pada *fully connected layers* [4]. Berbeda dengan metode tradisional yang memerlukan ekstraksi fitur manual, *CNN* secara otomatis mempelajari fitur yang relevan dari data citra. Ini memungkinkan model untuk mengidentifikasi pola – pola kompleks pada citra *MRI*, seperti tekstur, bentuk, dan tepi, yang sulit

dideteksi secara konsisten oleh metode lain. *CNN* terbukti efektif dalam mendeteksi pola visual pada citra medis, termasuk klasifikasi jenis tumor otak seperti glioma dan meningioma. Meskipun demikian, implementasi *CNN* menghadapi tantangan seperti kebutuhan dataset berkualitas tinggi, sumber daya komputasi yang besar, serta interpretasi hasil yang dapat diandalkan [5].

Penelitian ini bertujuan untuk mengimplementasikan *CNN* dalam klasifikasi tumor otak berdasarkan citra *MRI*, dengan fokus pada pengembangan model yang akurat dan efisien. Diharapkan hasil penelitian ini dapat berkontribusi pada peningkatan diagnosis dan pengobatan tumor otak secara klinis.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Penelitian terkait klasifikasi tumor otak dengan pendekatan *Convolutional Neural Network (CNN)* telah berkembang pesat dalam beberapa tahun terakhir. Salah satu penelitian yang relevan dilakukan oleh Mukti et al. [4] yang mengembangkan model *CNN* dengan 12 lapisan (*layers*) untuk mengklasifikasikan jenis tumor otak dari citra *MRI*. Dataset yang digunakan berasal dari Kaggle dan mencakup berbagai jenis tumor seperti glioma, meningioma, dan pituitary. Model *CNN* tersebut diuji dan menghasilkan akurasi sebesar 79% pada epoch ke-5. Meskipun model masih dalam tahap pengembangan, hasil ini menunjukkan potensi signifikan dalam pengembangan sistem diagnosis berbasis kecerdasan buatan. Penelitian ini juga menekankan pentingnya tahap *preprocessing* citra, seperti normalisasi dan augmentasi, sebagai langkah

penting dalam meningkatkan performa model. Pendekatan ini sangat relevan dalam pengolahan citra medis yang sering kali memiliki keterbatasan jumlah data dan kualitas citra yang bervariasi.

Dwaji et al. [6] dalam penelitiannya memfokuskan pada efektivitas penggunaan teknik augmentasi data dalam meningkatkan akurasi model CNN untuk klasifikasi tumor otak. Dalam kajiannya, digunakan berbagai teknik augmentasi seperti flipping, scaling, dan pengaturan brightness secara acak. Hasil penelitian menunjukkan bahwa dengan augmentasi yang tepat, model CNN memiliki daya generalisasi yang lebih baik dan mampu menghindari overfitting, terutama saat dataset berukuran kecil. Penelitian ini menyoroti bahwa augmentasi bukan hanya sekedar memperbanyak data, tetapi juga berperan penting dalam menciptakan variasi yang mendekati kondisi nyata pada citra medis. Temuan ini menjadi penting bagi pengembangan sistem klasifikasi citra medis di mana pengumpulan data berkualitas tinggi seringkali mahal dan sulit dilakukan.

Penelitian yang dilakukan oleh Husen [7] juga berkontribusi pada pengembangan klasifikasi citra MRI tumor otak menggunakan CNN. Dalam studinya, model CNN diimplementasikan secara penuh mulai dari tahap preprocessing, pelatihan model, hingga evaluasi akurasi. Penelitian ini menunjukkan bahwa CNN mampu mengekstraksi fitur spasial dari citra MRI dan secara otomatis membedakan jenis tumor otak berdasarkan pola yang dipelajari. Pendekatan end-to-end yang diterapkan dalam penelitian ini memberikan gambaran bahwa CNN merupakan salah satu metode paling efektif dalam pengolahan citra medis, karena mampu mengeliminasi kebutuhan akan teknik ekstraksi fitur manual yang kompleks. Selain itu, akurasi yang diperoleh membuktikan bahwa CNN sangat cocok diterapkan dalam sistem bantu diagnosis berbasis komputer.

Dalam konteks yang berbeda namun tetap relevan terhadap penerapan CNN dalam klasifikasi citra, Alwanda et al. [8] melakukan penelitian terhadap pengenalan lima objek doodle, yaitu pakaian, celana panjang, kursi, kupu-kupu, dan sepeda, menggunakan arsitektur LeNet-5. Penelitian ini mengumpulkan 150 gambar sebagai data pelatihan dan menunjukkan bahwa model CNN yang diterapkan mampu mencapai akurasi hingga 98% pada beberapa objek. Meskipun fokus penelitian bukan pada citra medis, studi ini memperlihatkan kemampuan CNN dalam mengenali pola-pola kompleks dari gambar dengan akurasi tinggi. LeNet-5 yang dikenal sebagai salah satu arsitektur CNN awal tetap menunjukkan performa baik dalam konteks klasifikasi visual sederhana, sehingga tetap relevan sebagai dasar pengembangan arsitektur lebih lanjut yang digunakan dalam bidang medis.

Penelitian oleh Andre et al. [9] menggunakan pendekatan arsitektur EfficientNet-B3 untuk klasifikasi tumor otak dari citra MRI. Dalam penelitian ini, CNN dirancang untuk mencapai efisiensi komputasi yang lebih tinggi tanpa mengorbankan

akurasi. Dataset yang digunakan berasal dari citra MRI yang mencakup berbagai tipe tumor, dan model yang dikembangkan menunjukkan hasil akurasi tinggi. Keunggulan utama dari EfficientNet-B3 adalah kemampuannya untuk mengimbangi ukuran model dan kinerja, menjadikannya pilihan ideal untuk digunakan pada perangkat dengan sumber daya terbatas seperti sistem diagnosis portabel. Studi ini menegaskan bahwa tidak hanya arsitektur dalam CNN yang penting, tetapi juga efisiensi dalam implementasi yang harus diperhitungkan, terutama dalam konteks penerapan nyata di dunia medis.

2.2. Deep Learning

Deep Learning (DL) merupakan salah satu cabang dari machine learning yang memanfaatkan jaringan saraf tiruan berlapis (deep neural network) untuk mempelajari dan mengekstraksi fitur dari data kompleks secara otomatis [9]. DL sangat efektif dalam menangani data tidak terstruktur seperti gambar, suara, dan teks, karena memiliki kemampuan untuk membentuk representasi data tingkat tinggi melalui lapisan-lapisan tersembunyi yang saling terhubung.

Konsep awal DL pertama kali diperkenalkan oleh Ivakhnenko dan Lapa pada tahun 1965 dengan membangun model jaringan saraf berlapis yang menggunakan fungsi aktivasi polinomial dan pendekatan statistik [10]. Perkembangan teknologi komputasi dan ketersediaan data besar (big data) mendorong DL menjadi salah satu teknik utama dalam berbagai aplikasi berbasis AI, termasuk dalam bidang kesehatan.

Dalam konteks pengolahan citra medis, DL banyak menggunakan arsitektur seperti Convolutional Neural Network (CNN) yang dirancang untuk mengidentifikasi pola spasial dalam gambar. CNN sangat efektif untuk tugas-tugas klasifikasi citra, termasuk deteksi tumor otak dari citra MRI [7].

2.3. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan arsitektur deep learning yang meniru pola komunikasi neuron pada otak manusia, sehingga mampu secara otomatis mengenali dan mengekstrak fitur penting dari citra. CNN banyak digunakan dalam berbagai aplikasi pemrosesan gambar [11], termasuk klasifikasi dan deteksi objek, dengan performa unggul dibandingkan metode tradisional [12].

Arsitektur CNN terdiri dari beberapa lapisan utama, yaitu lapisan konvolusi, aktivasi ReLU, pooling, flatten, fully connected, dan softmax. Lapisan konvolusi bertugas mengekstrak fitur menggunakan filter atau kernel, dengan ukuran output dapat dihitung menggunakan persamaan (1)

$$O = \frac{W - F + 2P}{S} + 1 \quad (1)$$

Dimana:

O = ukuran output,

W = ukuran input (lebar atau tinggi gambar),

F = ukuran filter/kernel,

P = jumlah padding (piksel tambahan di tepi gambar),
S = stride (langkah perpindahan filter).

Fungsi aktivasi ReLU menghilangkan nilai negatif untuk meningkatkan non-linearitas jaringan, sedangkan pooling mengurangi dimensi fitur untuk efisiensi komputasi dan mengurangi risiko overfitting [13].

Setelah proses ekstraksi fitur, data di-flatten menjadi vektor satu dimensi dan diteruskan ke fully connected layer untuk pengambilan keputusan klasifikasi. Fungsi softmax mengubah output menjadi probabilitas kelas, memungkinkan klasifikasi multi-kelas [14].

Evaluasi performa CNN dilakukan menggunakan confusion matrix yang mengelompokkan hasil klasifikasi ke dalam:

True Positive (TP): jumlah data positif yang diklasifikasi benar,

True Negative (TN): jumlah data negatif yang diklasifikasi benar,

False Positive (FP): jumlah data negatif yang salah diklasifikasi positif,

False Negative (FN): jumlah data positif yang salah diklasifikasi negatif [15].

Metrik evaluasi meliputi persamaan (2), (3), (4):

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$\text{Sensitivitas} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{Spesifisitas} = \frac{TN}{TN+FP} \quad (4)$$


Metrik ini mengukur ketepatan, kemampuan mendeteksi positif sebenarnya, dan kemampuan menolak negatif palsu, yang penting untuk aplikasi medis seperti klasifikasi tumor otak [3], [4].

Dengan kemampuan ekstraksi fitur otomatis dan klasifikasi yang akurat, CNN terus menjadi metode utama dalam analisis citra modern, termasuk dalam bidang medis, pengenalan wajah, dan sistem otomotif [4][16] [1].

2.4. Tumor Otak


Tumor otak merupakan pertumbuhan jaringan abnormal yang terjadi di dalam atau sekitar otak, yang dapat bersifat jinak maupun ganas. Tumor jinak biasanya tumbuh secara perlahan dan tidak menyerang jaringan sekitarnya, sedangkan tumor ganas bersifat agresif dan berpotensi menyebar ke bagian otak lain serta organ lain melalui sistem peredaran darah [2]. Tumor otak diklasifikasikan menjadi dua jenis utama, yaitu tumor primer yang berasal dari jaringan otak, dan tumor sekunder yang merupakan hasil metastasis dari kanker di organ lain seperti paru-paru, payudara, dan ginjal [17].

Organisasi Kesehatan Dunia (WHO) mengklasifikasikan tumor otak berdasarkan tingkat keganasannya dari Grade I (jinak) hingga Grade IV (sangat ganas), yang menjadi acuan dalam penentuan strategi pengobatan serta klasifikasi hasil terapi bagi pasien [17]. Jenis tumor otak yang umum dijumpai antara lain glioma, meningioma, adenoma hipofisis, dan medulloblastoma.



Gambar 1. Glioma tumor

Glioma merupakan kelompok tumor yang berasal dari sel glial, dan salah satu variannya yaitu glioblastoma multiforme (GBM), dikenal sebagai salah satu tumor otak paling agresif dan berbahaya [18].



Gambar 2. Meningioma tumor


Sementara itu, meningioma merupakan tumor yang berkembang di meninges (lapisan pelindung otak dan sumsum tulang belakang), yang umumnya bersifat jinak namun dalam beberapa kasus dapat menjadi ganas [18].

Faktor risiko yang diduga mempengaruhi pertumbuhan tumor otak meliputi faktor genetik, paparan radiasi ionisasi, bahan kimia beracun, infeksi virus tertentu, serta gaya hidup tidak sehat. Meskipun penyebab pasti belum sepenuhnya diketahui, beberapa studi menunjukkan bahwa mutasi genetik berperan penting dalam memicu pertumbuhan sel secara tidak terkendali [18].

3. METODE PENELITIAN

3.1. Flowchart Sistem

Secara umum *website* yang akan dikembangkan dapat digambarkan dalam *flowchart* berikut ini:




Gambar 3. Flowchart sistem deteksi tumor otak

Pada Gambar 3 adalah flowchart sistem yang diawali dengan *start* / mulai. Pengguna dapat menginputkan gambar untuk memklasifikasi tumor otak. Kemudian model akan memproses klasifikasi, dan menampilkan hasil klasifikasi. Hasil klasifikasi yang ditujukan untuk membantu proses pengambilan keputusan pengguna.

3.2. Flowchart Algoritma Metode

Flowchart berikut menggambarkan alur algoritma *Convolutional Neural Network* sebagai kerangka pembentukan model klasifikasi tumor otak



Gambar 4. Flowchart sistem deteksi tumor otak

Dalam penelitian ini, alur dari *CNN* seperti pada tergambar di Gambar 4, yang memiliki beberapa langkah penting. Pertama melakukan *pre-procesing* data. Bayangkan citra *Magnetic Resonance Imaging* (MRI) mentah yang perlu di siapkan terlebih dahulu agar sama dengan input model *CNN*, yaitu ukuran 256x256 piksel. Ada tiga kegiatan utama di sini: ukuran citra sesuaikan menggunakan teknik interpolasi piksel

$$x = \frac{x'}{Sx}, y = \frac{y'}{Sy}$$

(1)

$$Sx = \frac{Wbaru}{Wlama}, Sy = \frac{Hbaru}{Hlama} \quad (2)$$

rumus detailnya bisa dilihat pada Persamaan 1 dan 2. Kemudian, nilai intensitas pikselnya di normalisasi ke rentang antara 0 dan 1, ini membantu model belajar lebih stabil. Terakhir melakukan augmentasi data, seperti *brightness* secara *random* dan *contrast* secara *random*. Tujuannya agar variasi data latih lebih kaya, model tidak gampang *overfitting*, dan jumlah data untuk setiap kelas tumor jadi lebih seimbang.

Setelah data siap, masuklah tahap ekstraksi fitur. *CNN* secara cerdas akan mengambil pola-pola kunci dari citra *MRI*, misalnya tekstur atau bentuk yang khas, yang nantinya sangat berguna untuk proses klasifikasi agar lebih efisien dan tepat sasaran. Langkah selanjutnya adalah modifikasi model. Menggunakan dan menambahkan beberapa lapisan: *flatten layer* untuk mengubah data fitur yang tadinya multidimensi menjadi satu dimensi saja dengan sebesar 128 dan *relu* untuk membiarkan nilai positif dan membuang nilai negatif. Dropout 2 kali dengan nilai 0.4 dan 0.2 untuk mencegah *overfitting*. Dan *softmax* untuk mengubah *output numerik* yang dapat ditafsirkan setiap kemungkinan. Mengatur untuk proses pelatihan, di mana *optimizer Adam* sebesar 0.00005 dan *loss function*-nya. Setelah itu, model *training* dengan menggunakan data latih yang sudah disiapkan tadi. Selama proses ini, bobot-bobot di dalam *CNN* akan terus menerus diperbarui. Melakukan evaluasi model dengan mengukur berbagai metrik, seperti akurasi, *recall*, dan *support*.

4. HASIL DAN PEMBAHASAN

Model *Convolutional Neural Network* di kembangkan menggunakan bahasa pemrograman python dengan *Tensorflow* dan *Keras*. Implementasi dilakukan menggunakan arsitektur *VGG16* yang merupakan model *deep learning* yang terdiri dari 13 *convolutional layers* dan 3 *fully connected layers*, dan memiliki keunggulan dalam mendeteksi pola pada gambar.

Dengan mensimulasikan proses metode *cnn* dengan input matrik citra dengan 5x5 dibawah

$$I = \begin{bmatrix} 8 & 9 & 9 & 0 & 9 \\ 5 & 5 & 2 & 7 & 8 \\ 2 & 6 & 9 & 8 & 5 \\ 3 & 6 & 7 & 1 & 0 \\ 3 & 10 & 5 & 8 & 1 \end{bmatrix}$$

Gambar 5 Simulasi Citra Input

Untuk mengekstraksi fitur bentuk dan tekstur dari citra, digunakan filter konvolusi berukuran 3 x 3.

$$K = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Persamaan diatas merupakan bentuk dari kernel dengan matrix 3 x 3. Proses Konvolusi dilakukan dengan menggeser kernel ke seluruh citra dan menghitung hasil dot pada setiap langkah. Sebagai contoh pada bagian kiri atas, hasil konvolusi dihitung sebagai

$$(8X0) + (9X1) + (9X0) + (5X0) + (5X-4) + (2X1) + (2X0) + (6X1) + (9X0) = 2$$

Setelah semua posisi dihitung, diperoleh *feature map* hasil konvolusi sebagai berikut

$$I = \begin{bmatrix} 2 & 22 & -10 \\ -2 & -13 & -10 \\ 2 & -7 & 19 \end{bmatrix}$$

Selanjutnya fungsi aktivasi ReLu diterapkan untuk menghilangkan nilai negatif dengan persamaan 3.

$$f(x) = \max(0, x) \quad (3)$$

Sehingga *feature map* setelah aktivasi ReLu adalah

$$I = \begin{bmatrix} 2 & 22 & 0 \\ 0 & 0 & 0 \\ 2 & 0 & 19 \end{bmatrix}$$

Setelah ReLu maka akan melalui proses pooling untuk mereduksi dimensi matriks fitur sekaligus untuk mempertahankan informasi penting dengan ukuran 2x2 yang mengambil nilai maksimum dari setiap blok area dengan hasil perhitungan

$$P = \begin{bmatrix} 22 & 22 \\ 2 & 19 \end{bmatrix}$$

Hasil dari pooling akan diubah menjadi 1 dimensi dan akan dimasukkan ke layer *fully connected layer* untuk klasifikasi dengan bobot

$$W = \begin{bmatrix} 0.1 & 0.3 \\ 0.5 & 0.8 \\ 0.4 & 0.2 \\ 0.9 & 0.6 \end{bmatrix} \quad (4)$$

Persamaan diatas merupakan contoh random nilai bobot yang akan dihitung dengan perhitungan hasil sebelumnya yang telah di *flatening* maka akan muncul hasil

$$z = [31.1 \quad 36]$$

Terkahir yaitu dengan menggunakan aktivasi softmax output dengan rumus persamaan (5)

$$\text{softmax}(z_j) = \frac{e^{z_j}}{\sum_{k=1}^M e^{z_k}} \quad (5)$$

maka didapatkan hasil

$$P1 = 0.463487$$

$$P2 = 0.536513$$

Berdasarkan hasil simulasi dapat disimpulkan bahwa CNN berhasil mengklasifikasi bahwa gambar tersebut lebih condong dengan hasil klasifikasi class P2, karena memiliki nilai lebih dominan dengan besaran 0.536513.

Pengujian performa *Convolution Neural Network* (CNN) dilakukan dengan cara membandingkan hasil yang diharapkan dengan jawaban aktual yang diberikan oleh dokter ahli. Hasil yang didapat dari membandingkan akan dihitung menggunakan metode evaluasi *confosion matrix*. Dengan 3 class yaitu *glioma*, *meningioma*, dan *no tumor*. Pengujian performa *Convolution Neural Network* ditampilkan secara rinci di Tabel 1

Tabel 1. Pengujian Model CNN

No	Nama File	Label Dokter	Klasifikasi Model	Convidence Value	Hasil Klasifikasi
1.	Glioma_01	Glioma	Glioma	80,18 %	✓
2.	Glioma_02	Glioma	Glioma	68,04 %	✓
3.	Glioma_03	Glioma	Glioma	85,05 %	✓
4.	Glioma_04	Glioma	Glioma	85,63 %	✓
5.	Glioma_05	Glioma	Glioma	59,70 %	✓
6.	Glioma_06	Glioma	Glioma	86,27 %	✓
7.	Glioma_07	Glioma	Glioma	80,38 %	✓
8.	Glioma_08	Glioma	Glioma	93,33 %	✓
9.	Glioma_09	Glioma	Glioma	89,31 %	✓
10.	Glioma_10	Glioma	Meningioma	49,31 %	✗
11.	Meningioma_01	Meningioma	Meningioma	86,11 %	✓
12.	Meningioma_02	Meningioma	Meningioma	79,31 %	✓
13.	Meningioma_03	Meningioma	Meningioma	82,32 %	✓
14.	Notumor_01	No tumor	No tumor	45,04 %	✓
15.	Notumor_02	No tumor	No tumor	59,03 %	✓

Keterangan:

✓: Benar

✗: Salah

Tabel 1 menampilkan hasil dari pengujian model *Convolutional Neural Network* tanpa noise. Hasil klasifikasi yang didapatkan dari total 15 data pengujian, benar sebanyak 14 data dan salah sebanyak 1 data, maka persentase kebenaran sebesar 93%. Hasil tersebut digunakan untuk menghitung nilai evaluasi model menggunakan metode *confusion matrix*. Hasil diberi label sesuai dengan pengujian dengan kategori berikut: *True Positive (TP)* - data positif yang diklasifikasi benar, *True Negative (TN)* - data negatif yang diklasifikasi benar, *False Positive (FP)* - data negatif yang diklasifikasi sebagai positif, *False Negative (FN)* - data positif yang diklasifikasi sebagai negatif.

Tabel 2. Pengujian Model CNN dengan noise


No	Nama File	Label Dokter	Klasifikasi Model	Convience Value	Hasil Klasifikasi
1.	Glioma_01	Glioma	Glioma	66,78 %	✓
2.	Glioma_02	Glioma	No Tumor	70,61 %	✗
3.	Glioma_03	Glioma	Glioma	98,39 %	✓
4.	Glioma_04	Glioma	Glioma	75,58 %	✓
5.	Glioma_05	Glioma	Glioma	71,95 %	✓
6.	Glioma_06	Glioma	Glioma	76,51 %	✓
7.	Glioma_07	Glioma	Glioma	64,37 %	✓
8.	Glioma_08	Glioma	Glioma	77,67 %	✓
9.	Glioma_09	Glioma	Glioma	96,61 %	✓
10.	Glioma_10	Glioma	Glioma	34,38 %	✓
11.	Meningioma_01	Meningioma	Meningioma	63,77 %	✓
12.	Meningioma_02	Meningioma	Meningioma	61,78 %	✓
13.	Meningioma_03	Meningioma	No tumor	63,69 %	✗
14.	Notumor_01	No tumor	No tumor	58,62 %	✓
15.	Notumor_02	No tumor	No tumor	81,43 %	✓

Keterangan:

✓: Benar

✗: Salah


Berdasarkan hasil pengujian terhadap citra MRI yang telah diberi noise, terjadi penurunan akurasi klasifikasi dan confidence value pada beberapa sampel. Hasil klasifikasi dengan data *noise* yang didapatkan dari total 15 data pengujian, benar sebanyak 13 data dan salah sebanyak 2 data, maka persentase kebenaran sebesar 86%. Hal ini menunjukkan bahwa model CNN yang dibangun masih sensitif terhadap gangguan noise, dengan perbedaan sebesar 1 data. Beberapa citra yang sebelumnya berhasil diklasifikasikan dengan benar menjadi salah setelah ditambahkan noise.



Gambar 6 Grafik Training

Gambar 6 menunjukkan grafik akurasi model selama proses pelatihan dan validasi dalam 10 *epoch*. Akurasi *training* (garis hijau) mengalami peningkatan yang signifikan hingga mendekati 99%, sedangkan akurasi validasi (garis biru) stabil di kisaran 90–93% setelah epoch ke-3. Hal ini menunjukkan bahwa model mampu belajar dengan baik dari data latih, meskipun terdapat sedikit perbedaan akurasi antara data latih dan

data validasi yang mengindikasikan potensi *overfitting* ringan.



Gambar 7 Grafik Validasi

Gambar 7 menampilkan grafik *loss* selama proses *training* dan validasi model dalam 10 *epoch*. Nilai *loss* pada data *training* (garis merah) terus menurun secara konsisten hingga di bawah 0.1, sedangkan *loss* pada data validasi (garis ungu) cenderung fluktuatif dan stabil di kisaran 0.2 hingga 0.4. Perbedaan tren ini menunjukkan bahwa meskipun model belajar dengan baik pada data latih, terdapat potensi *overfitting* yang terlihat dari ketidakstabilan *loss* pada data validasi.

Pengujian metode dengan menggunakan data sebanyak 500, 750, dan 1000 data. Dengan hasil pengujian membandingkan jumlah data yang berbeda, untuk menguji tingkat akurasi model. Serta lama komputasi dari proses pembuatan model di Tabel 3.

Tabel 3 Pengujian metode data training bervariasi

No	Jumlah Data Training per Class	Persentase Training Akurasi	Lama waktu Training
1.	500 data	98.82 %	1 menit 30 detik
2.	750 data	98.67 %	2 menit 25 detik
3.	1000 data	97.42 %	3 menit 20 detik

Tabel 3 menunjukkan kesimpulan bahwa semakin banyak jumlah data training maka semakin lama pula lama waktu training. Persentase training akurasi semakin menurun seiring bertambahnya jumlah data training, diindikasikan bahwa ada *micro overfitting*.

Hasil tersebut digunakan untuk menghitung nilai evaluasi model menggunakan metode *confusion matrix*. Hasil diberi label sesuai dengan pengujian dengan kategori berikut: *True Positive (TP)* - data positif yang diklasifikasi benar, *True Negative (TN)* - data negatif yang diklasifikasi benar, *False Positive (FP)* - data negatif yang diklasifikasi sebagai positif, *False Negative (FN)* - data positif yang diklasifikasi sebagai negatif. Hasil yang diperoleh dapat diambil dengan hasil *confusion matrix* seperti ditunjukkan pada Tabel 4

Tabel 4 Confusion Matrix

Predict \ Actual	Glioma	Meningioma	No Tumor
Glioma	9	1	0
Meningioma	0	3	0
No Tumor	0	0	2

Hasil tersebut digunakan untuk menghitung nilai akurasi, sensitivitas, dan spesifisitas. Hasil yang diperoleh sebagai berikut:

1. Kelas Glioma:

TP (*True Positive*) : 9

TN (*True Negative*) : 5

FP (*False Positive*) : 0

FN (*False Negative*) : 1

$$\text{Sensitivitas} = \left(\frac{TP}{TP + FN} \right) \times 100\% = \left(\frac{9}{9 + 1} \right) \times 100\% = 90\%$$

$$\text{Spesifisitas} = \left(\frac{TN}{TN + FP} \right) \times 100\% = \left(\frac{5}{5 + 0} \right) \times 100\% = 100\%$$

2. Kelas Meningioma:

TP (*True Positive*) : 3

TN (*True Negative*) : 11

FP (*False Positive*) : 1

FN (*False Negative*) : 0

$$\text{Sensitivitas} = \left(\frac{TP}{TP + FN} \right) \times 100\% = \left(\frac{3}{3 + 0} \right) \times 100\% = 100\%$$

$$\text{Spesifisitas} = \left(\frac{TN}{TN + FP} \right) \times 100\% = \left(\frac{11}{11 + 1} \right) \times 100\% = 91,67\%$$

3. Kelas No tumor:

TP (*True Positive*) : 2

TN (*True Negative*) : 13

FP (*False Positive*) : 0

FN (*False Negative*) : 0

$$\text{Sensitivitas} = \left(\frac{TP}{TP + FN} \right) \times 100\% = \left(\frac{2}{2 + 0} \right) \times 100\% = 100\%$$

$$\text{Spesifisitas} = \left(\frac{TN}{TN + FP} \right) \times 100\% = \left(\frac{13}{13 + 0} \right) \times 100\% = 100\%$$

Akurasi keseluruhan =

$$\left(\frac{TP + TN}{TP + TN + FP + FN} \right) \times 100\% = \left(\frac{14}{15} \right) \times 100\% = 93,3\%$$

Rata – Rata Sensitivitas

$$= \left(\frac{90 + 100 + 100}{3} \right) \times 100\% = 96,7\%$$

Rata – Rata Spesifisitas

$$= \left(\frac{100 + 91,67 + 100}{3} \right) \times 100\% = 97,2\%$$

Berdasarkan hasil evaluasi, model menghasilkan akurasi keseluruhan sebesar 93,3%, yang menunjukkan bahwa sekitar 93% berhasil diklasifikasikan dengan benar oleh model. Nilai rata-rata sensitivitas sebesar 96,7% menunjukkan kemampuan model dalam mendeteksi kasus positif dengan sangat baik. Nilai rata-rata spesifisitas sebesar 97,2% menegaskan bahwa model juga mampu membedakan kasus negatif dengan tingkat kesalahan yang rendah.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa aplikasi yang dikembangkan berhasil membaca, menerima unggahan gambar MRI, serta menampilkan hasil klasifikasi jenis tumor menggunakan metode CNN, dengan keseluruhan sistem berfungsi sesuai harapan. Sistem deteksi ini mampu mengklasifikasikan citra *Magnetic Resonance Imaging (MRI)* dan memberikan hasil jenis klasifikasi tumor dengan akurasi model sebesar 93%, yang menunjukkan kemampuan klasifikasi benar yang tinggi. Lebih lanjut, model mencapai sensitivitas 96,7% dalam mendeteksi kasus positif dan spesifisitas 97,2% dalam membedakan kasus negatif secara baik. Untuk pengembangan di masa mendatang, disarankan agar penelitian selanjutnya dapat mengeksplorasi penggunaan arsitektur alternatif seperti ResNet sebagai pembanding arsitektur metode CNN yang telah digunakan. Selain itu, direkomendasikan pula untuk memperkaya dan memperbanyak dataset dengan menambahkan variasi jenis tumor lain, termasuk

secara spesifik tumor pituitary, sambil tetap memberikan perhatian penuh terhadap aspek sensitivitas dan kerahasiaan data pasien

DAFTAR PUSTAKA

- [1] R. Andre, B. Wahyu, and R. Purbaningtyas, "Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3," *J. IT*, vol. 11, no. 3, pp. 55–59, 2021, [Online]. Available: <https://jurnal.umj.ac.id/index.php/just-it/index>
- [2] I.- Trianiza, A. Sidiq, and A. N. Lisdawati, "Restorasi Citra Magnetic Resonance Imaging (Mri) Ruang Katerisasi Jantung Rsud Ulin Banjarmasin Menggunakan Metode Blind Deconvolution," *Al Jazari J. Ilm. Tek. Mesin*, vol. 9, no. 1, pp. 7–10, 2024, doi: 10.31602/al-jazari.v9i1.12803.
- [3] E. Setia Budi, A. Nofriyaldi Chan, P. Priscillia Alda, and M. Arif Fauzi Idris, "RESOLUSI: Rekayasa Teknik Informatika dan Informasi Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network," *Media Online*, vol. 4, no. 5, p. 509, 2024, [Online]. Available: <https://djournals.com/resolusi>
- [4] M. A. Mukti, A. T. Kurniawan, S. Bahri, N. Husin, B. Yanto, and F. Asmen, "Akurasi 12 Layer Convolutional Neural Network (CNN) Untuk Jenis Tumor Otak Dari Hasil Citra MRI Dengan Google Colab Dan Dataset Kaggle," *Riau J. Comput. Sci.*, vol. 10, no. 2, pp. 135–145, 2024, [Online]. Available: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor->
- [5] N. Nafiyah, "Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network," *J. Inform. J. Pengemb. IT*, vol. 8, no. 3, pp. 213–219, 2023, doi: 10.30591/jpit.v8i3.4985.
- [6] A. Z. Dwiaji, B. Junianto, and S. P. Haswanto, "Literature Review : Penggunaan Convolutional Neural Networks Untuk Klasifikasi Citra Tumor Otak," vol. 2, no. 3, pp. 491–496, 2024.
- [7] D. Husen, "Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network," *bit-Tech*, vol. 7, no. 1, pp. 143–152, 2024, doi: 10.32877/bt.v7i1.1576.
- [8] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *J. Algoritma*, vol. 1, no. 1, pp. 45–56, 2020, doi: 10.35957/algoritme.v1i1.434.
- [9] A. C. Alves, A. Ferreira, B. Puladi, J. Egger, and V. Alves, "Deep Dive into MRI: Exploring Deep Learning Applications in 0.55T and 7T MRI," pp. 1–38, 2024, [Online]. Available: <http://arxiv.org/abs/2407.01318>
- [10] S. Mulyana and I. Muthmainnah, "Analisis Perbandingan Tingkat Akurasi Algoritma Cnn Dan Svm Dalam Klasifikasi Pada Daun Gedi, Daun Pepaya Dan Daun Ubi," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 4, pp. 6157–6162, 2024, doi: 10.36040/jati.v8i4.10144.
- [11] S. Satwikayana, S. Adi Wibowo, and N. Vendyansyah, "Sistem Presensi Mahasiswa Otomatis Pada Zoom Meeting Menggunakan Face Recognition Dengan Metode Convolutional Neural Network Berbasis Web," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 5, no. 2, pp. 785–793, 2021, doi: 10.36040/jati.v5i2.3762.
- [12] J. Antivirus, "Klasifikasi Pola Sidik Jari," vol. 10, no. 2, pp. 50–55, 2016.
- [13] S. Sriani and A. Nabila, "Implementasi Deep Learning Untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (Cnn)," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1836–1843, 2024, doi: 10.23960/jitet.v12i3.4457.
- [14] A. H. Artya, J. Jasril, S. Sanjaya, F. Syafria, and E. Budianita, "Implementasi Convolutional Neural Network Untuk Klasifikasi Daging Menggunakan Fitur Ekstraksi Tekstur dan Arsitektur AlexNet," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 3, p. 635, 2022, doi: 10.30865/jurikom.v9i3.4177.
- [15] E. Albalawi *et al.*, "Enhancing brain tumor classification in MRI scans with a multi-layer customized convolutional neural network approach," *Front. Comput. Neurosci.*, vol. 18, no. June, pp. 1–19, 2024, doi: 10.3389/fncom.2024.1418546.
- [16] A. Rizky, S. Achmadi, A. F. Setiawan, and T. Informatika, "PENERAPAN DATA MINING DENGAN ALGORITMA KNN UNTUK MENENTUKAN TINGKAT KERUSAKAN DRAINASE KOTA JOMBANG," vol. 8, no. 5, pp. 8471–8478, 2024.
- [17] F. Citra R, F. Indriyani, and I. R. Rahadjeng, "Klasifikasi Tumor Otak Berbasis Magnetic Resonance Imaging Menggunakan Algoritma Convolutional Neural Network," *Digit. Transform. Technol.*, vol. 3, no. 2, pp. 918–924, 2024, doi: 10.47709/digitech.v3i2.3469.
- [18] M. Ghozali, "Jurnal Review: Pengobatan Klinis Tumor Otak pada Orang Dewasa," *J. Phi J. Pendidik. Fis. dan Fis. Terap.*, vol. 2, no. 1, p. 1, 2021, doi: 10.22373/p-jpft.v2i1.8302.