

Klasifikasi Jenis Tumor Otak Melalui Citra MRI dengan Menggunakan Convolutional Neural Network

Dyah Listianing Tyas¹, Frendy Rocky Rumambi², Arpen Patanduk³, Roynaldo Christopel Johanes Mailangkay⁴,

^{1,2}Program Studi Informatika / Fakultas Sains dan Teknologi,
Universitas Prisma Manado

Jl. Pomorouw No. 113, Kel. Tikala Baru, Kec. Tikala, Manado, Sulawesi Utara

^{3,4}Program Studi Teknik Informatika / Fakultas Teknik
Universitas Sam Ratulangi

Jl.Kampus Unsrat, Bahu, Manado 95115, Sulawesi Utara, Indonesia

dyahlistianingtyas@gmail.com¹, frensrumbambi@gmail.com², arpenpatanduk026@student.unsrat.ac.id³,
roynaldomailangkay026@student.unsrat.ac.id⁴

Abstrak. Pendekslsian tumor otak pada citra MRI menggunakan metode Convolutional Neural Network (CNN) semakin berkembang dalam diagnosis medis berbasis pencitraan. CNN memungkinkan identifikasi tumor seperti glioma, meningioma, dan tumor pituitari dengan akurasi tinggi melalui ekstraksi fitur otomatis dari citra MRI. Penelitian ini bertujuan untuk mengevaluasi efektivitas CNN dalam segmentasi dan klasifikasi tumor otak, serta meningkatkan efisiensi dan akurasi deteksi. Metode yang digunakan mencakup pengumpulan data MRI, preprocessing citra, augmentasi data, serta penerapan transfer learning untuk mengatasi tantangan keterbatasan data dan overfitting. Hasil penelitian menunjukkan model CNN mampu mencapai akurasi 96,57% pada data uji dengan precision = 96,70%, recall = 96,59%, dan F1-score = 96,60% yang sangat tinggi untuk semua kelas. Meskipun demikian, tantangan terkait komputasi tinggi dan variasi citra MRI masih perlu diatasi. Penelitian ini menegaskan pentingnya penggunaan dataset besar dan beragam untuk meningkatkan performa model dalam aplikasi klinis deteksi tumor otak.

Kata Kunci: CNN, Deep Learning, Deteksi Tumor Otak, Klasifikasi, MRI

1 Pendahuluan

Tumor otak merupakan penyakit yang berdampak besar terhadap kualitas hidup seseorang dan merupakan salah satu penyebab utama kematian akibat kanker di seluruh dunia. Menurut data dari Global Health Observatory, jumlah kasus tumor otak terus meningkat setiap tahunnya, dengan tingkat kematian yang signifikan di berbagai negara, termasuk Indonesia. Di Indonesia, lebih dari 5.900 kasus tumor otak tercatat pada tahun 2021, dengan angka kematian yang terus meningkat. Tumor otak terbagi menjadi dua jenis utama: tumor primer yang berkembang di otak itu sendiri, dan tumor sekunder yang berasal dari kanker di bagian tubuh lain dan menyebar ke otak [1]. Deteksi dini tumor otak sangat penting untuk meningkatkan peluang kesembuhan, namun metode manual yang digunakan oleh ahli radiologi sering kali memakan waktu dan rentan terhadap kesalahan [2].

Seiring dengan kemajuan teknologi, penerapan metode deep learning, khususnya Convolutional Neural Networks (CNN), telah terbukti efektif dalam mendeteksi tumor otak pada citra MRI. CNN dapat mengenali pola-pola kompleks dalam citra medis dengan tingkat akurasi yang lebih tinggi dibandingkan metode tradisional yang bergantung pada pengalaman ahli radiologi. CNN bekerja dengan mengekstraksi fitur-fitur penting dalam citra dan mengklasifikasikannya berdasarkan pembelajaran dari data pelatihan. Penelitian yang dilakukan oleh Khan et al. menunjukkan bahwa penggunaan CNN untuk mengklasifikasikan tumor otak dapat menghasilkan akurasi yang sangat tinggi dalam identifikasi berbagai jenis tumor (glioma, pituitari, meningioma) [21]. Dengan demikian, CNN menawarkan solusi yang sangat menjanjikan untuk meningkatkan akurasi diagnosis dan mempercepat proses deteksi dini tumor otak.

Namun, penerapan CNN pada citra MRI tumor otak masih menghadapi beberapa tantangan, terutama dalam hal overfitting dan keterbatasan jumlah data yang besar. Oleh karena itu, teknik augmentasi data dan transfer learning telah diterapkan untuk mengatasi tantangan ini. Augmentasi data memperbesar variasi citra

pelatihan, sementara transfer learning memungkinkan model untuk menggunakan pengetahuan yang telah dilatih pada dataset besar lainnya [3], [4], [19]. Penelitian ini bertujuan untuk mengeksplorasi dan mengembangkan penggunaan CNN dalam klasifikasi tumor otak pada citra MRI, serta mengidentifikasi faktor-faktor yang dapat meningkatkan akurasi model.

Convolutional Neural Networks (CNN) telah menjadi metode yang sangat efektif dalam deep learning, khususnya untuk pemrosesan citra medis seperti klasifikasi tumor otak dari citra MRI. CNN bekerja dengan mengaplikasikan beberapa lapisan konvolusi yang mengekstraksi fitur dari citra, yang kemudian digunakan untuk klasifikasi atau deteksi objek. Berbeda dengan metode konvensional lainnya, seperti regresi atau klasifikasi berbasis fitur tangan, CNN terbukti lebih unggul karena kemampuannya mengenali pola-pola kompleks dalam citra medis yang sulit diidentifikasi menggunakan metode tradisional [2]. Selain itu, CNN tidak memerlukan pengetahuan domain yang mendalam dan dapat belajar secara otomatis dari data besar yang kompleks, memungkinkan model untuk belajar secara mandiri dari data pelatihan [1], [15], [17].

Beberapa penelitian sebelumnya telah menunjukkan bahwa CNN dapat mengklasifikasikan tumor otak dengan akurasi yang sangat tinggi berdasarkan citra MRI. Gómez-Guzmán et al. menemukan bahwa model CNN dapat mengklasifikasikan tumor otak dengan tingkat akurasi yang sangat tinggi, membuktikan bahwa CNN dapat diandalkan untuk mendeteksi berbagai jenis tumor otak seperti glioma, pituitari, dan meningioma [5]. Penggunaan arsitektur CNN yang lebih kompleks, seperti ResNet-50, VGG16, dan MobileNetV2, juga terbukti meningkatkan hasil klasifikasi [13], [15]. Arsitektur yang lebih dalam memungkinkan model untuk mengekstraksi fitur yang lebih kompleks, yang sangat membantu dalam mengenali pola pada citra MRI tumor otak yang sulit dideteksi sebelumnya [3], [4], [14], [18]. Penelitian oleh Santoso et al. juga menunjukkan bahwa penggabungan arsitektur yang lebih dalam pada CNN dapat meningkatkan kemampuan model dalam memproses citra dengan lebih baik, berfokus pada penyempurnaan hyperparameter untuk meningkatkan akurasi deteksi [8].

Namun, penerapan CNN dalam klasifikasi tumor otak berbasis citra MRI tidak tanpa tantangan. Salah satu tantangan utama adalah ketergantungan pada dataset besar dan bervariasi. Model CNN memerlukan dataset yang besar agar dapat belajar secara efektif dan menghasilkan klasifikasi yang akurat. Untuk mengatasi masalah ini, augmentasi data sering digunakan untuk memperbesar variasi citra pelatihan tanpa perlu pengumpulan data tambahan secara manual. Teknik augmentasi seperti rotasi, zoom, translasi, dan flipping memungkinkan model untuk belajar dari lebih banyak variasi citra, yang membantu meningkatkan ketahanan model terhadap perubahan dalam data dunia nyata [5], [6]. Augmentasi data juga memperkaya dataset pelatihan dengan memperkenalkan citra yang lebih beragam, yang sangat berguna ketika dataset asli terbatas dalam jumlah atau variasinya.

Selain augmentasi data, transfer learning juga telah menjadi teknik yang sangat populer untuk meningkatkan kinerja CNN dalam klasifikasi tumor otak. Dalam transfer learning, model yang telah dilatih sebelumnya pada dataset yang lebih besar dan lebih umum, seperti ImageNet, digunakan untuk membangun model CNN yang lebih spesifik untuk tugas tertentu, seperti klasifikasi tumor otak. Teknik ini mengurangi ketergantungan pada dataset besar dan memungkinkan model untuk belajar lebih cepat dan lebih efisien, meskipun hanya dengan dataset yang lebih kecil [3], [7]. Penelitian oleh Ramadhan et al. menunjukkan bahwa transfer learning dengan CNN dapat meningkatkan akurasi klasifikasi tumor otak dengan signifikan, bahkan ketika dataset yang tersedia terbatas [9], [23]. Hal ini menunjukkan fleksibilitas transfer learning dalam menyesuaikan model dengan berbagai jenis dataset. Meskipun CNN menawarkan solusi yang efektif dalam klasifikasi tumor otak, masalah overfitting tetap menjadi tantangan. Overfitting terjadi ketika model terlalu mempelajari data pelatihan dan kesulitan dalam menggeneralisasi pola pada data baru yang belum pernah dilihat sebelumnya [12]. Untuk mengurangi risiko ini, digunakan teknik regularisasi seperti dropout dan L2 regularization. Dropout bekerja dengan cara menghilangkan beberapa neuron secara acak selama proses pelatihan, sehingga mencegah model bergantung secara berlebihan pada neuron-neuron tertentu. L2 regularization menambahkan penalti pada bobot model untuk mencegah bobot menjadi terlalu besar, yang dapat menyebabkan model mengenali pola yang tidak relevan pada data pelatihan [8], [9]. Teknik-teknik ini terbukti efektif dalam membantu model CNN meningkatkan kemampuan generalisasi, sehingga dapat memberikan hasil klasifikasi yang lebih akurat pada data baru yang belum pernah ditemui sebelumnya. Temuan ini juga diperkuat oleh penelitian Zahoor et al. [6]. Selain teknik-teknik yang disebutkan di atas, beberapa penelitian mengembangkan arsitektur baru untuk meningkatkan kinerja CNN dalam klasifikasi tumor otak.

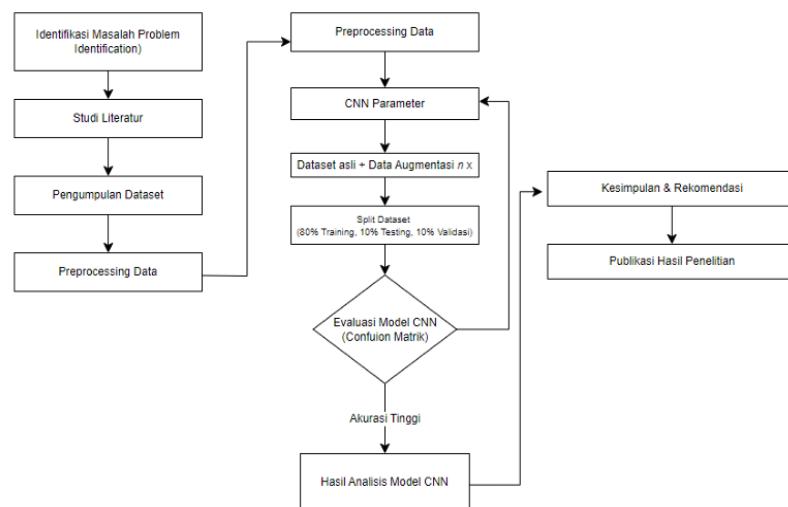
Zahoor et al. [6] mengembangkan model CNN yang menggabungkan residual learning untuk meningkatkan akurasi klasifikasi tumor otak pada citra MRI. Residual learning memungkinkan model untuk fokus pada fitur-fitur penting dengan mengurangi beban pemrosesan yang tidak relevan, yang sangat berguna untuk klasifikasi tumor yang lebih kompleks. Pendekatan ini terbukti efektif dalam mengidentifikasi tumor yang lebih kecil atau tersembunyi pada citra MRI, yang sebelumnya sulit dideteksi menggunakan model CNN standar [10], [16], [20], [22]. Penelitian oleh Ramadhan et al. [9] juga menggunakan transfer learning untuk meningkatkan akurasi klasifikasi tumor otak dengan model CNN yang lebih kecil, menekankan pentingnya penggabungan teknik yang lebih efisien untuk meningkatkan akurasi klasifikasi.

Oleh karena itu, meskipun CNN memiliki banyak keunggulan dalam mendeteksi tumor otak, masih diperlukan penelitian lebih lanjut untuk mengatasi berbagai tantangan, seperti permasalahan overfitting, ketergantungan terhadap dataset yang besar, dan variasi kualitas citra yang dapat mempengaruhi performa model. Penelitian lebih lanjut mengenai augmentasi data, transfer learning, dan teknik regularisasi yang lebih baik dapat meningkatkan efisiensi dan akurasi deteksi tumor otak dalam aplikasi klinis. Dengan kata lain, sistem deteksi tumor otak yang menggunakan CNN memiliki potensi besar untuk menjadi alat bantu yang andal dalam mempercepat dan meningkatkan akurasi proses diagnosis, mendukung pengobatan yang lebih tepat sasaran, dan meningkatkan peluang kesembuhan pasien [11], [12].

2 Metodologi Penelitian

2.1. Jenis dan Pendekatan Penelitian

Penelitian ini tergolong sebagai penelitian kuantitatif karena mengandalkan analisis numerik dalam mengevaluasi performa model klasifikasi, dengan menggunakan metrik seperti akurasi, precision, recall, dan F1-score. Pendekatan yang diterapkan adalah pendekatan eksperimental terapan di bidang kecerdasan buatan, khususnya dalam deep learning untuk klasifikasi citra medis. Fokus utama penelitian ini adalah merancang dan mengembangkan model Convolutional Neural Network (CNN) guna mendeteksi serta mengklasifikasikan tumor otak berdasarkan citra MRI.



Gambar 1. Alur Penelitian

Pendekatan eksperimental dipilih karena memberikan keleluasaan bagi peneliti untuk mengontrol variabel input, melatih model menggunakan data pelatihan, serta menguji kemampuan generalisasi model pada data pengujian yang belum pernah digunakan sebelumnya. Pendekatan ini memungkinkan evaluasi yang sistematis terhadap performa model dalam kondisi yang terkontrol. Tujuannya adalah untuk mengevaluasi efektivitas arsitektur CNN dan preprocessing data yang digunakan dalam mendeteksi jenis tumor otak. Pendekatan ini juga memungkinkan iterasi berulang dalam pemilihan parameter dan arsitektur hingga diperoleh model dengan performa optimal.

2.2. Metode Penelitian

Penelitian yang kami lakukan ini menggunakan metode rekayasa eksperimental yang dilakukan melalui pemrograman Python melalui Google Collaboratory, dengan merancang pipeline klasifikasi citra yang

mengimplementasikan teknik deep learning. Seluruh tahapan dilakukan secara terprogram dan otomatis menggunakan lingkungan Google Colab, yang menyediakan sumber daya GPU untuk mempercepat proses pelatihan. Penelitian ini melibatkan beberapa tahap penting, mulai dari pengumpulan data, prapemrosesan, pelatihan model CNN, evaluasi performa, hingga interpretasi hasil melalui metrik dan visualisasi.

Model CNN dibangun menggunakan pendekatan sekuensial, di mana setiap layer ditambahkan satu per satu, menciptakan jalur komputasi yang linier dari input hingga output. CNN dipilih karena kemampuannya dalam mengekstraksi fitur spasial lokal dari citra, yang sangat penting dalam konteks medis untuk mengidentifikasi struktur abnormal seperti tumor. Arsitektur CNN dioptimalkan melalui percobaan berulang terhadap jumlah layer, jumlah neuron, ukuran filter, serta teknik regularisasi seperti dropout dan batch normalization.

2.3. Teknik Pengumpulan Data

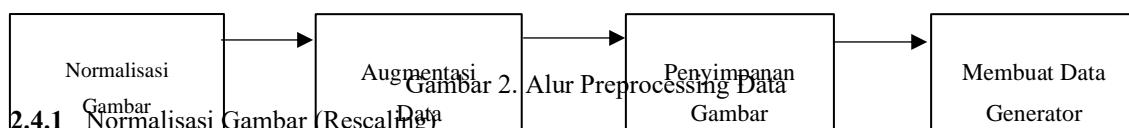
Data yang digunakan diperoleh dari dataset Brain Tumor MRI Dataset milik Masoud Nickparvar yang tersedia di Kaggle. Dataset ini terdiri dari empat kelas yaitu glioma tumor, meningioma tumor, pituitary tumor, dan no tumor. Total terdapat 7.023 citra MRI otak berwarna (RGB) yang sudah terstruktur dalam direktori Training dan Testing, sehingga tidak diperlukan proses labeling manual tambahan. Data diunduh dan disimpan di Google Drive, lalu dimuat ke dalam program menggunakan fungsi `flow_from_directory()` dari `ImageDataGenerator`, yang secara otomatis membaca struktur direktori dan mengasosiasikan gambar ke labelnya. Proses ini mempermudah pipeline klasifikasi dan mempercepat eksperimen. Pembagian data dilakukan secara eksplisit oleh penyedia dataset, sehingga menjaga validitas data uji yang belum pernah dilihat model sebelumnya.

Tabel 1. Jumlah Dataset Setiap Kelas Pada Penyakit Tumor

Jenis	Training	Testing
Glioma	1321	300
Meningioma	1339	306
No tumor	1595	405
Pituitary	1457	300
Total	5712	1311

2.4. Tahapan Penelitian

Tahap pertama adalah persiapan data, yang mencakup pengunduhan dan penyimpanan dataset ke Google Drive, serta pemisahan data ke dalam folder pelatihan dan pengujian. Jumlah citra pelatihan sebanyak 6.112 dan data pengujian sebanyak 1.321, yang mencerminkan distribusi data yang cukup besar untuk pelatihan model CNN. Tahap kedua adalah preprocessing data, berikut alur preprocessing data yang dilakukan:



`ImageDataGenerator` digunakan untuk melakukan normalisasi gambar dengan membagi nilai pixel gambar dengan 255.0. Nilai pixel gambar pada umumnya berkisar antara 0 hingga 255, tetapi dalam pelatihan model deep learning, sangat penting untuk menormalisasi gambar agar nilai pixel berada dalam rentang [0, 1]. Ini dilakukan dengan mengatur parameter `rescale=1/255`. Proses ini akan membuat setiap nilai pixel gambar dibagi dengan 255 sehingga gambar akan memiliki nilai antara 0 dan 1, yang membuat pelatihan model lebih stabil dan mempercepat konvergensi. Dua objek `train_datagen` dan `test_datagen` dibuat untuk normalisasi data pelatihan dan pengujian masing-masing.

2.4.2 Augmentasi Data

Pada augmentasi data kami menerapkannya pada data pelatihan untuk meningkatkan keberagaman dataset dan membantu model dalam generalisasi. Augmentasi memungkinkan model belajar dari variasi gambar tanpa menambah data fisik. Dalam objek `train_datagen`, transformasi yang diterapkan meliputi: normalisasi gambar dengan `rescale=1/255`, rotasi acak hingga 40 derajat (`rotation_range=40`), penggeseran gambar dalam rentang 20% dari lebar dan tinggi (`width_shift_range=0.2` dan `height_shift_range=0.2`), pemotongan (`shear`) dengan `shear_range=0.2`, zooming acak hingga 20% (`zoom_range=0.2`), pembalikan horizontal (`horizontal_flip=True`), dan pengisian ruang kosong dengan piksel terdekat (`fill_mode='nearest'`). Untuk data pengujian (`test_datagen`),

hanya dilakukan normalisasi dengan rescale=1/255 tanpa augmentasi, agar data tetap sesuai dengan kondisi aslinya untuk evaluasi model yang akurat.

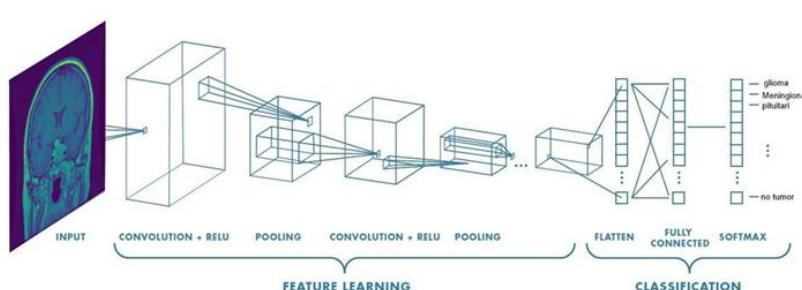
2.4.3 Penyimpanan Gambar

Disini kami menggunakan sebuah fungsi bernama preprocess_and_save_images dibuat untuk memproses gambar-gambar dalam dataset. Fungsi ini bekerja dengan cara memuat gambar dari folder input, mengubah ukurannya menjadi 240x240 piksel, dan melakukan normalisasi dengan membagi nilai pixel dengan 255 untuk mengubahnya ke dalam rentang [0, 1]. Setelah itu, fungsi ini juga menerapkan augmentasi data untuk meningkatkan keberagaman gambar, seperti rotasi, pergeseran (baik horizontal maupun vertikal), dan perubahan zoom. Augmentasi data ini penting untuk melatih model agar bisa mengenali pola yang lebih variatif dan tidak hanya bergantung pada gambar yang ada dalam dataset asli. Setelah gambar diproses dan diaugmentasi, gambar tersebut disimpan kembali ke folder tujuan yang telah ditentukan, sesuai dengan kelasnya. Selanjutnya, fungsi ini diterapkan pada dua set data utama: data pelatihan (train) dan data pengujian (test). Gambar yang telah diproses untuk masing-masing set data disimpan di folder Training_afterpreprocess dan Testing_afterpreprocess. Proses ini memastikan bahwa gambar yang akan digunakan untuk pelatihan model dan pengujian sudah siap, terstruktur dengan baik, dan memiliki variasi yang cukup melalui teknik augmentasi. Dengan demikian, model dapat belajar dengan lebih efektif dan menggeneralisasi pola dengan baik pada data baru.

2.4.4 Membuat Data Generator

Kami membuat dua generator untuk memuat data pelatihan dan pengujian secara otomatis menggunakan ImageDataGenerator. Fungsi flow_from_directory digunakan untuk menghasilkan batch gambar dari folder yang telah diproses. Generator train_generator menghasilkan batch gambar dari dataset pelatihan, di mana gambar diubah ukurannya sesuai dengan parameter target_size=(img_height, img_width), dengan batch_size menentukan jumlah gambar per batch dan class_mode='categorical' menunjukkan lebih dari dua kelas dengan output one-hot encoded labels. Sebaliknya, test_generator digunakan untuk dataset pengujian, memuat gambar dari folder test_preprocessed_dir dengan ukuran yang sama. Di sini, shuffle=False memastikan urutan data tetap konsisten selama evaluasi, yang penting untuk menilai akurasi model pada data yang tidak dikenali sebelumnya. Seperti pada train_generator, class_mode='categorical' juga diterapkan pada data pengujian.

Tahap ketiga dari pembuatan model CNN berfokus pada pembangunan arsitektur jaringan, di mana setiap layer disusun untuk mendukung proses ekstraksi fitur dan klasifikasi citra secara efektif.



Gambar 3. Arsitektur Layer CNN

Proses ini dimulai dengan penerapan layer konvolusi pertama menggunakan 32 filter berukuran 5x5 yang memproses citra berukuran 224x224 piksel, dengan padding "same" agar dimensi keluaran tetap. Layer ini diikuti oleh MaxPooling2D berukuran 2x2 untuk mengurangi dimensi spasial tanpa menambah parameter, serta BatchNormalization untuk menstabilkan distribusi output dan mempercepat pelatihan. Selanjutnya, dua layer konvolusi tambahan masing-masing menggunakan 64 dan 128 filter untuk mengekstraksi fitur yang lebih kompleks, diikuti oleh pooling dan normalisasi serupa. Setelah seluruh proses konvolusi, citra diubah menjadi vektor 1D melalui Flatten, lalu diproses oleh beberapa layer Dense dengan aktivasi ReLU. Untuk mengurangi risiko overfitting, digunakan Dropout dan BatchNormalization di antara layer-layer Dense. Dan untuk lapisan output menggunakan Dense dengan empat unit dan aktivasi Softmax untuk mengklasifikasikan citra ke dalam empat kelas: glioma, meningioma, pituitari, dan non-tumor. Tahap selanjutnya adalah pelatihan model, di mana CNN dikompilasi dengan fungsi loss categorical crossentropy dan optimizer Adam dengan learning rate 0.0001.

Proses pelatihan berlangsung selama 10 epoch dan menggunakan batch size sebesar 32. Selama pelatihan, performa model dipantau melalui data validasi, dan mekanisme early stopping diterapkan untuk menghentikan pelatihan jika tidak ada peningkatan pada loss validasi selama tiga epoch berturut-turut, sehingga overfitting dapat dicegah. Setelah model selesai dilatih, evaluasi dilakukan terhadap dataset pengujian yang tidak digunakan dalam proses pelatihan untuk mengukur performa generalisasi. Evaluasi ini mencakup penghitungan metrik-metrik seperti akurasi, precision, recall, dan F1-score baik secara keseluruhan maupun per kelas. Selain itu, digunakan confusion matrix untuk mengidentifikasi pola kesalahan klasifikasi antar kelas, serta visualisasi grafik akurasi dan loss untuk melihat kestabilan pelatihan.

Beberapa citra uji juga ditampilkan bersama hasil prediksi sebagai bagian dari analisis kualitatif. Tahap terakhir adalah interpretasi dari hasil evaluasi model. Proses ini bertujuan untuk menilai sejauh mana model mampu mengklasifikasikan citra baru secara akurat, dengan berfokus pada data uji yang tidak pernah terlibat dalam proses pelatihan. Evaluasi dimulai dengan menghasilkan prediksi dari model, lalu membandingkannya dengan label asli untuk menghitung akurasi, precision, recall, dan F1-score. Akurasi menunjukkan proporsi klasifikasi yang benar terhadap seluruh prediksi, namun pada data yang tidak seimbang, metrik ini bisa menyesatkan. Oleh karena itu, precision dan recall digunakan untuk mengukur ketepatan dan sensitivitas prediksi, sedangkan F1-score berfungsi sebagai ukuran keseimbangan antara keduanya. Metrik-metrik ini juga dihitung untuk masing-masing kelas, sehingga kinerja model terhadap tiap jenis tumor bisa dinilai secara mendalam. Confusion matrix digunakan untuk menggambarkan distribusi prediksi dan label aktual, yang membantu dalam mengenali pola kesalahan spesifik. Evaluasi ini menjadi dasar penting untuk menilai efektivitas model serta memberikan arah bagi pengembangan lebih lanjut.

3. Hasil dan Pembahasan

3.1. Preprocessing

Proses preprocessing sangat penting dalam analisis citra medis, karena bertujuan untuk mempersiapkan data citra agar dapat digunakan dengan efektif dalam pelatihan model deep learning. Tanpa preprocessing yang tepat, model dapat mengalami kesulitan dalam mempelajari fitur yang relevan dari citra. Dimana pada tahap normalisasi setiap nilai pixel dalam citra dibagi dengan 255.0, sehingga nilai pixel berubah menjadi rentang antara 0 dan 1. Proses ini bertujuan untuk mengurangi skala perbedaan antar nilai pixel yang dapat mempengaruhi kinerja model. Normalisasi membantu mempercepat konvergensi model karena model akan belajar lebih cepat ketika data berada dalam rentang yang seragam. Tanpa normalisasi, model dapat mengalami kesulitan dalam mempelajari hubungan antar fitur citra dengan cepat. Sedangkan Augmentasi itu sendiri adalah teknik yang digunakan untuk memperkaya dataset pelatihan dengan menghasilkan variasi baru dari citra asli. Augmentasi dilakukan dengan melakukan transformasi acak pada citra, seperti rotasi, pergeseran (shift) horizontal dan vertikal, zoom, dan flipping. Teknik ini sangat penting ketika dataset terbatas, karena memungkinkan model untuk belajar dari lebih banyak variasi citra tanpa harus menambah data secara fisik. Dengan augmentasi, model dapat lebih robust dan tahan terhadap variasi citra yang ditemukan di dunia nyata, misalnya perubahan sudut pandang, posisi, atau skala objek dalam citra.

3.2. Pembuatan Model CNN dan Training

Model CNN yang dikembangkan dalam penelitian ini terdiri dari tiga blok konvolusi bertingkat, masing-masing menggunakan kernel 5x5 dan aktivasi ReLU, diikuti oleh pooling dan batch normalization. Setelah ekstraksi fitur, model menggunakan beberapa fully connected layer dengan dropout untuk mencegah overfitting, dan diakhiri dengan output layer softmax yang mengklasifikasikan citra MRI otak ke dalam empat kelas: glioma, meningioma, pituitary, dan no tumor. Model dikompilasi dengan optimizer Adam dan loss function categorical crossentropy, serta dilatih dengan data augmentasi untuk meningkatkan variasi citra. Pelatihan dilakukan selama 10 epoch dengan penerapan early stopping untuk mencegah overfitting, yang menghentikan pelatihan secara otomatis jika akurasi pada data validasi tidak meningkat setelah beberapa epoch, guna mencegah model belajar terlalu banyak dari data pelatihan dan kehilangan kemampuan generalisasi.

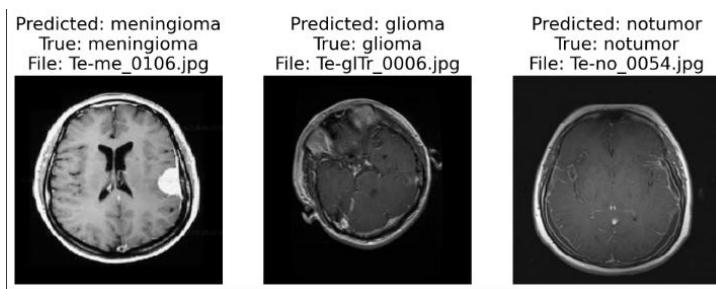
Tabel 2. Akurasi dan loss training dan validasi

Epoch	Waktu (s)	Accuracy	Loss	Val_Accuracy	Val_Loss
1	2156	0.5616	1.1053	0.5496	1.0348
2	32	0.7760	0.5941	0.7487	0.5843

3	32	0.8579	0.4027	0.8668	0.3657
4	32	0.8940	0.2967	0.9137	0.2455
5	32	0.9308	0.2122	0.9084	0.2302
6	41	0.9421	0.1796	0.9357	0.1853
7	41	0.9614	0.1227	0.9394	0.1690
8	32	0.9683	0.0993	0.9387	0.1821
9	37	0.9735	0.0806	0.9523	0.1329
10	32	0.9732	0.0795	0.9508	0.1618
11	33	0.9828	0.0587	0.9629	0.1008
12	32	0.9858	0.0527	0.9621	0.1407
13	37	0.9851	0.0531	0.9531	0.1399
14	38	0.9839	0.0557	0.9599	0.1460

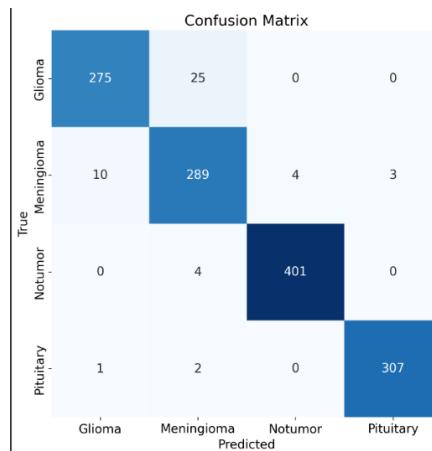
3.3. Testing

Hasil pelatihan menunjukkan peningkatan akurasi pelatihan dari 55,27% pada epoch pertama menjadi 97,95% pada epoch kesepuluh, dan akurasi validasi meningkat dari 37,32% menjadi 96,59%, dengan loss validasi turun dari 1,5385 menjadi 0,1110. Hal ini menunjukkan model belajar dengan stabil dan menghasilkan generalisasi yang baik terhadap data validasi.



Gambar 4. Pengujian Prediksi Gambar Tumor Otak

Evaluasi lanjutan dilakukan pada data pengujian yang berjumlah 1.321 citra. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 96,57% dan nilai loss sebesar 0,1115 pada data uji. Kinerja yang sangat baik ini juga tercermin dalam laporan klasifikasi, dengan nilai precision, recall, dan F1-score yang tinggi untuk semua kelas. Misalnya, kelas 'glioma' memperoleh precision sebesar 0,91 dan recall 0,97, sedangkan kelas 'meningioma' memiliki precision 0,96 dan recall 0,90. Kelas 'pituitary' dan 'notumor' bahkan mencapai precision dan recall sebesar 1,00, menunjukkan bahwa model sangat andal dalam membedakan jenis tumor otak yang berbeda.



Gambar 5. Confusion Matrix Hasil Pengujian Model

Confusion matrix memperlihatkan hasil prediksi yang sangat akurat dengan sebagian besar citra diklasifikasikan dengan benar. Sebagai contoh, dari 11 sampel untuk kelas glioma, 10 diklasifikasikan dengan

benar, dan dari 10 sampel pituitary, seluruhnya diklasifikasikan tepat. Satu-satunya ketidakseimbangan yang cukup mencolok terdapat pada kelas meningioma, di mana dua dari enam gambar diklasifikasikan ke kelas yang salah. Hal ini bisa disebabkan oleh kemiripan visual antara meningioma dan jenis tumor lain atau variasi bentuk yang tinggi dalam kelas tersebut. Namun secara keseluruhan, hasil confusion matrix mendukung hasil metrik evaluasi bahwa model bekerja sangat baik.

Tabel 3. Hasil Klasifikasi Model CNN

Kelas	Precision	Recall	F1-Score	Support
glioma	0.96	0.92	0.94	300
meningioma	0.90	0.94	0.92	306
notumor	0.99	0.99	0.99	405
pituitary	0.99	0.99	0.99	310
Akurasi	0.96	0.96	0.96	1321

Selain itu, evaluasi juga mencakup metrik makro seperti precision (96,70%), recall (96,59%), dan F1-score (96,60%), yang menunjukkan bahwa model tidak hanya akurat secara keseluruhan tetapi juga seimbang dalam menangani distribusi antar kelas. Ini penting karena dalam banyak kasus klasifikasi medis, model yang hanya unggul pada satu kelas namun gagal pada lainnya bisa berbahaya dalam konteks klinis. Oleh karena itu, performa tinggi dan seimbang yang dicapai dalam eksperimen ini menegaskan bahwa pendekatan arsitektur CNN yang digunakan sudah sangat sesuai dengan tugas klasifikasi citra MRI otak. Hasil visualisasi terhadap citra uji juga menunjukkan bahwa prediksi model sangat mendekati label sebenarnya. Dalam enam sampel citra yang ditampilkan, hampir semua gambar berhasil diklasifikasikan sesuai dengan labelnya. Hal ini menunjukkan bahwa model telah belajar mengenali fitur spasial penting dalam citra MRI, seperti bentuk, tekstur, dan pola intensitas yang khas untuk tiap jenis tumor. Keberhasilan ini didukung oleh proses augmentasi data yang cukup agresif, serta arsitektur model yang memanfaatkan inisialisasi He dan Glorot untuk mengoptimalkan pembelajaran dari data awal.

4. Kesimpulan dan Saran

Penelitian ini berhasil mengembangkan model Convolutional Neural Network (CNN) yang efisien dalam mendeteksi dan mengklasifikasikan berbagai jenis tumor otak berdasarkan citra MRI. Model ini menunjukkan peningkatan akurasi yang signifikan dari 55,27% pada epoch pertama menjadi 97,95% pada epoch kesepuluh, dengan akurasi validasi 96,59% dan akurasi pengujian 96,57%. Teknik augmentasi data dan regularisasi terbukti penting dalam meningkatkan variasi dan kualitas pembelajaran, sementara pemilihan arsitektur dan parameter pelatihan yang tepat sangat menentukan performa model. Hasil evaluasi menunjukkan nilai precision, recall, dan F1-score yang sangat tinggi untuk semua kelas tumor, menjadikan model ini sangat bermanfaat dalam aplikasi medis. Model ini menawarkan manfaat besar dalam diagnosis dan deteksi dini tumor otak, mengurangi ketergantungan pada evaluasi manual oleh ahli radiologi, dan menghemat waktu serta biaya dalam diagnosis medis. Penggunaan model ini dapat mempercepat penanganan penyakit dan meningkatkan kualitas hidup pasien. Untuk pengembangan selanjutnya, penelitian ini menyarankan penerapan transfer learning dengan arsitektur pretrained, penggunaan dataset yang lebih besar, serta integrasi model dalam aplikasi berbasis web atau mobile untuk digunakan langsung oleh tenaga medis. Evaluasi terhadap interpretabilitas model juga penting untuk memastikan transparansi hasil klasifikasi dalam konteks klinis.

Referensi

- [1] Hidayaturrahman, F. (2024). Penerapan Deep Learning untuk Klasifikasi Tumor Otak Menggunakan Dataset MRI. Universitas Dinamika. Retrieved from <https://repository.dinamika.ac.id/id/eprint/8393>
- [2] Mukti, M. A., Nugroho, A., & Wibowo, R. S. (2024). Penerapan Metode CNN (Convolutional Neural Network) Untuk Klasifikasi Tumor Otak. Jurnal Teknologi dan Rekayasa Sistem, 2(1), 1–10. <https://doi.org/10.54732/jtrs.v2i1.482>
- [3] Nafi'iyah, N., & Wardhani, R. (2023). Perbandingan Arsitektur CNN dalam Mendeteksi Tumor Otak Menggunakan Citra MRI. Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, 7(3), 1033–1040. Retrieved from <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/19708>

- [4] Khan, H. A., Jue, W., Mushtaq, M., & Mushtaq, M. U. (2020). Brain tumor classification in MRI image using convolutional neural network. *Math Biosci Eng*, 17(5), 6203–6216. <https://ssrn.com/abstract=3894961>
- [5] Gómez-Guzmán, M. A., Jiménez-Beristaín, L., García-Guerrero, E. E., López-Bonilla, O. R., Tamayo-Perez, U. J., Esqueda-Elizondo, J. J., Palomino-Vizcaino, K., & Inzunza-González, E. (2023). Classifying Brain Tumors on Magnetic Resonance Imaging by Using Convolutional Neural Networks. *Electronics* (Switzerland), 12(4). <https://doi.org/10.3390/electronics12040955>
- [6] Zahoor, M. M., Khan, S. H., Alahmadi, T. J., Alsahfi, T., Mazroa, A. S. A., Sakr, H. A., Alqahtani, S., Albanyan, A., & Alshemaimri, B. K. (2024). Brain Tumor MRI Classification Using a Novel Deep Residual and Regional CNN. *Biomedicines*, 12(7). <https://doi.org/10.3390/biomedicines12071395>
- [7] Tjahyaningtjas, H. P. A., Rumala, D. J., Angkoso, C. V., Fanani, N. Z., Santoso, J., Sensusiat, A. D., Ooijen, P. M. A. V., Ketut Eddy Purnama, I. K. E., & Purnomo, M. H. (2021). Brain Tumor Classification in MRI Images Using En-CNN. *International Journal of Intelligent Engineering and Systems*, 14(4), 437–451. <https://doi.org/10.22266/ijies2021.0831.38>
- [8] Santoso, F. Y., Sediyono, E., & Purnomo, H. D. (2024). Optimalisasi Hyper Parameter Convolutional Neural Networks Menggunakan Ant Colony Optimization. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 11(2), 243–248. <https://doi.org/10.25126/jtiik.20241127105>
- [9] Ramadhan, M., Iskandar Mulyana, D., Betty Yel, M., & Tinggi Ilmu Komputer Cipta Karya Informatika Jl Raden, S. (2022). OPTIMASI ALGORITMA CNN MENGGUNAKAN METODE TRANSFER LEARNING UNTUK KLASIFIKASI CITRA X-RAY PARU-PARU PNEUMONIA DAN NON-PNEUMONIA. *Jurnal Teknik Informatika Kaputama (JTIK)*, 6(2).
- [10] Dimara, D. L. S., Putri, S. W., Amelia, R., Arishandy, Z. I., & Rizki, A. M. (2023). Penerapan Convolutional Neural Network (CNN) dalam Klasifikasi Citra MRI untuk Deteksi Tumor Otak Manusia. *KERNEL: Jurnal Riset Inovasi Bidang Informatika Dan Pendidikan Informatika*, 4(2), 70–77. <https://doi.org/10.31284/j.kernel.2023.v4i2.6960>
- [11] FUADAH, Y. N., UBAIDULLAH, I. D., IBRAHIM, N., TALININGSING, F. F., SY, N. K., & PRAMUDITHO, M. A. (2022). Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(3), 728. <https://doi.org/10.26760/elkomika.v10i3.728>
- [12] Rachmawanto, E. H., Hermanto, D., Pratama, Z., & Sari, C. A. (2024). Performa Convolutional Neural Network Dalam Deep Layers Resnet-50 Untuk Klasifikasi MRI Tumor Otak. Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK) 2024.
- [13] Kurniawan, M. B., & Utami, E. (2025). Performance Comparison of ResNet50, VGG16, and MobileNetV2 for Brain Tumor Classification on MRI Images. *Sistemasi: Jurnal Sistem Informasi* 14(2). <http://sistemasi.ftik.unisi.ac.id>
- [14] Wardhani, R., & Nafi'iyah, N. (2023). Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network. 8(3). *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, 8(3).
- [15] Gayathri, T., & Kumar, K. S. (2024). Brain Tumor Segmentation and Classification Using CNN Pre-Trained VGG-16 Model in MRI Images. *IIUM Engineering Journal*, 25(2), 196–211. <https://doi.org/10.31436/iujmej.v25i2.2963>
- [16] Husen, D. (2024). Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network. *Bit-Tech*, 7(1), 143–152. <https://doi.org/10.32877/bt.v7i1.1576>
- [17] Husen, D. (2024). Performance Evaluation Of Cnn Models With Various Data Augmentation Techniques On MRI Images For Brain Tumor Classification. *TEKNIKMEDIA*, 5(2).
- [18] Amalia, K., Magdalena, K., Saidah, S. (2022). Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN. *E-Proceeding of Engineering*, 8(6), 3247-3254.
- [19] Candra, D., Wibisono, G., Ayu, M., & Afrad, M. (2024). LEDGER: Journal Informatic and Information Technology Transfer Learning model Convolutional Neural Network menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI. In OPEN ACCESS LEDGER (Vol. 3, Issue 1).
- [20] Avşar, E., & Salçın, K. (2019). Detection and classification of brain tumours from MRI images using faster R-CNN. *Tehnički Glasnik*, 13(4), 337–342. <https://doi.org/10.31803/tg-20190712095507>
- [21] Mzoughi, H., Njeh, I., Wali, A., Slima, M. ben, BenHamida, A., Mhiri, C., & Mahfoudhe, K. ben. (2020). Deep Multi-Scale 3D Convolutional Neural Network (CNN) for MRI Gliomas Brain Tumor Classification. *Journal of Digital Imaging*, 33(4), 903–915. <https://doi.org/10.1007/s10278-020-00347-9>
- [22] Bhanumathi, V., Sangeetha, R. (2019). CNN Based Training and Classification of MRI Brain Images. 2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS).
- [23] Mukti, M. A., Kurniawan, A. T., Bahri, S., Husin, N., Yanto, B., & Asmen, F. (2024). Akurasi 12 Layer Convolutional Neural Network (CNN) Untuk Jenis Tumor Otak Dari Hasil Citra MRI Dengan Google Colab Dan Dataset Kaggle. In *Riau Journal of Computer Science* (Vol. 10, Issue 2). <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor>