

# Perbandingan Performa Arsitektur CNN Terhadap Klasifikasi Tumor Otak Menggunakan Data MRI

Sekar Dewi Harnum Saputri\*, Achmad Lukman, Muhamad Irsan

Fakultas Informatika, Telkom University, Bandung, Indonesia

Email: <sup>1,\*</sup>sekarputri@students.telkomuniversity.ac.id, <sup>2</sup>alukman@telkomuniversity.ac.id, <sup>3</sup>irsanfaiz@telkomuniversity.ac.id

Email Penulis Korespondensi: sekarputri@students.telkomuniversity.ac.id

Submitted: 12/01/2025; Accepted: 26/03/2025; Published: 27/03/2025

**Abstrak**—Penelitian ini membahas perbandingan performa empat arsitektur *Convolutional Neural Network* (CNN) dalam klasifikasi tumor otak menggunakan citra histopatologi. CNN telah membuktikan efektivitasnya dalam meningkatkan akurasi dan efisiensi diagnosis medis berbasis citra. Penelitian ini membandingkan empat arsitektur populer, yaitu ResNet, AlexNet, InceptionNet, dan VGG12, menggunakan dataset citra histopatologi dengan total 2.145 gambar yang terbagi menjadi subset pelatihan (70%), validasi (15%), dan pengujian (15%). Hasil penelitian menunjukkan bahwa model VGG12 mencapai akurasi terbaik sebanyak 98,0%, diikuti oleh InceptionNet dengan akurasi 97,3%. Model ResNet memperoleh akurasi 94,3%, sedangkan AlexNet memiliki akurasi 93,2%. Selain itu, model VGG12 membuktikan performa yang konsisten dengan angka precision, recall, dan F1-Score yang tinggi, menjadikannya pilihan unggul untuk aplikasi medis. Penelitian ini memberikan wawasan mendalam mengenai kelebihan dan keterbatasan masing-masing arsitektur CNN, serta panduan implementasi untuk mendukung pengembangan aplikasi diagnosis medis berbasis citra secara efisien dan akurat.

**Kata Kunci:** CNN; Resnet; Alexnet; Inception; Vgg12; Tumor Otak; Citra Histopathological

**Abstract**—This study discusses the performance comparison of four *Convolutional Neural Network* (CNN) architectures in brain tumor classification using histopathology images. CNN has proven its effectiveness in improving the accuracy and efficiency of image-based medical diagnosis. This study compares four popular architectures, namely ResNet, AlexNet, InceptionNet, and VGG12, using a histopathology image dataset with a total of 2,145 images divided into training (70%), validation (15%), and testing (15%) subsets. The results show that the VGG12 model achieves the best accuracy of 98.0%, followed by InceptionNet with an accuracy of 97.3%. The ResNet model achieves an accuracy of 94.3%, while AlexNet has an accuracy of 93.2%. In addition, the VGG12 model shows consistent performance with high precision, recall, and F1-Score values, making it a superior choice for medical applications. This study provides in-depth insights into the advantages and limitations of each CNN architecture, as well as implementation guidelines to support the development of image-based medical diagnosis applications efficiently and accurately.

**Keywords:** CNN; Resnet; Alexnet; Inception; Vgg12; Brain Tumor; Histopathological Image

## 1. PENDAHULUAN

Tumor otak adalah satu diantara penyakit dengan dampak yang signifikan secara menyeluruh. Menurut data *World Health Organization* (WHO), tumor otak menyumbang sekitar 3-5% dari total kasus kanker yang terdiagnosis setiap tahunnya, dengan tingkat mortalitas yang cukup tinggi. Selain itu, tumor otak berkontribusi pada hilangnya produktivitas secara ekonomi, terutama pada individu usia produktif. Di Amerika Serikat, sekitar 24.000 kasus baru tumor otak ditemukan setiap tahunnya, dan sekitar 16.000 kematian dilaporkan terkait penyakit ini. Tumor otak satu diantara banyak penyakit dengan tingkat mortalitas yang signifikan, menyumbang 3-5% dari total kasus kanker global setiap tahunnya [1] [2]. Diagnosis dini yang akurat memainkan peran penting dalam meningkatkan peluang kesembuhan pasien. Namun, proses diagnosis secara manual yang melibatkan analisis citra histopatologi memiliki keterbatasan, seperti membutuhkan waktu yang lama dan rentan terhadap kesalahan akibat subyektivitas manusia [3]. Kemajuan teknologi dalam bidang kecerdasan buatan, khususnya deep learning, telah membuka peluang baru dalam pengolahan citra medis. *Convolutional Neural Network* (CNN) yakni satu diantara beberapa pendekatan deep learning yang paling menjanjikan, dengan kemampuan untuk mengenali pola kompleks dalam data citra yang tidak dapat diidentifikasi oleh metode tradisional [4]. Beberapa arsitektur CNN seperti ResNet, AlexNet, InceptionNet, dan VGG12 telah banyak digunakan untuk berbagai tugas klasifikasi citra, termasuk untuk aplikasi medis [5]. ResNet (Residual Network) dikenal dengan kemampuan untuk mengatasi vanishing gradient melalui residual connections, yang memungkinkan pelatihan jaringan yang sangat dalam [6]. AlexNet merupakan salah satu arsitektur CNN awal yang memelopori penggunaan GPU dalam pelatihan model besar [7]. InceptionNet menggabungkan konsep multi-level feature extraction dalam satu layer [8] sementara VGG12 terkenal dengan desain sederhana tetapi efisien menggunakan layer konvolusi bertumpuk [9]. Analisis komparatif antara empat arsitektur ini memberikan wawasan penting dalam memilih model yang paling sesuai untuk klasifikasi tumor otak. ResNet menawarkan akurasi tinggi tetapi memerlukan waktu pelatihan yang lebih lama [10]. AlexNet dan InceptionNet unggul dalam efisiensi waktu pelatihan, sedangkan VGG12 berada di tengah-tengah dengan keseimbangan antara akurasi dan waktu pelatihan [11]. Studi ini mengevaluasi performa keempat model menurut akurasi, presisi, recall, dan F1-score, memakai dataset citra histopatologi yang telah diaugmentasi [12]. Selain itu, penelitian ini mengidentifikasi beberapa tantangan utama dalam klasifikasi tumor otak berbasis citra histopatologi, termasuk keterbatasan dataset dan kebutuhan akan solusi yang dapat diimplementasikan dalam lingkungan medis nyata [13]. Dengan membandingkan keempat arsitektur ini, penelitian ini memberikan rekomendasi praktis bagi pengembangan model deep learning yang optimal untuk aplikasi medis [14].



Pada penelitian ini, fokus utama adalah membandingkan performa empat arsitektur Convolutional Neural Network (CNN), yaitu ResNet, AlexNet, InceptionNet, dan VGG12, dalam tugas klasifikasi tumor otak menggunakan citra histopatologi. Pemilihan topik ini penting karena tumor otak, sebagai salah satu jenis kanker paling mematikan, membutuhkan diagnosis yang akurat dan cepat untuk meningkatkan kualitas hidup pasien[2]. Metode tradisional yang bergantung pada analisis manual oleh ahli patologi sering kali menghadapi kendala seperti waktu yang lama dan tingkat keakuratan yang bervariasi[3]. Di sisi lain, CNN telah terbukti mampu memberikan performa luar biasa dalam tugas pengenalan pola pada citra, termasuk citra medis [4][5]. Dalam evaluasi performa arsitektur CNN untuk klasifikasi tumor otak, metrik seperti precision, recall, dan F1-score digunakan karena menyatakan gambaran secara merata dibandingkan hanya mengandalkan akurasi. Akurasi memang mengukur persentase prediksi yang benar terhadap seluruh data, tetapi seringkali tidak cukup untuk menilai performa model, terutama jika dataset tidak seimbang. Misalnya, dalam kasus di mana jumlah gambar kategori "non-tumor" jauh lebih banyak daripada "tumor", model yang hanya memprediksi "non-tumor" dapat mencapai akurasi tinggi tanpa benar-benar memahami pola data. Dalam konteks medis, pendekatan seperti ini sangat berbahaya karena kesalahan dalam mendeteksi tumor dapat berdampak serius pada kesehatan pasien[13].

Precision menjadi metrik penting karena menunjukkan seberapa andal model dalam memprediksi kasus positif, yaitu tumor. Ketika model memprediksi bahwa sebuah gambar menunjukkan adanya tumor, precision membantu mengevaluasi sejauh mana prediksi tersebut benar. Dalam dunia medis, prediksi positif yang salah (false positives) dapat menyebabkan kecemasan pasien, penggunaan sumber daya yang tidak perlu, atau bahkan tindakan medis yang berlebihan. Oleh karena itu, memiliki precision yang tinggi membantu memastikan bahwa diagnosis tumor tidak dibuat secara sembarangan[15].

Di sisi lain, recall berfungsi mengukur seberapa baik model mendeteksi semua kasus tumor yang sebenarnya ada. Dalam klasifikasi tumor otak, recall sangat penting karena kegagalan mendeteksi keberadaan tumor (false negatives) dapat berakibat fatal. Model dengan recall yang rendah akan melewatkan banyak kasus tumor, yang berarti pasien tidak akan mendapatkan perawatan yang mereka butuhkan tepat waktu[16]. Untuk mendapatkan evaluasi yang seimbang antara precision dan recall, F1-score digunakan. F1-score yakni mayoritas harmonis antara precision dan recall, yang menyatakan gambaran performa model secara keseluruhan. Metrik ini sangat berguna dalam situasi seperti klasifikasi tumor, di mana kedua aspek—reliabilitas prediksi positif dan kemampuan mendeteksi semua kasus positif sama pentingnya. F1-score membantu memastikan bahwa model tidak hanya sensitif terhadap keberadaan tumor, tetapi juga dapat meminimalkan kesalahan prediksi yang tidak perlu[17]. Dengan demikian, precision, recall, dan F1-score menyalurkan wawasan yang lebih jauh mengenai performa model dalam aplikasi yang kritis seperti diagnosis medis. Ketiga metrik ini membantu meyakinkan bahwa model yang dipilih bukan sekedar menghasilkan akurasi tinggi, tetapi juga dapat diandalkan untuk memberikan prediksi yang tepat dan menyeluruh, menjadikannya alat yang aman dan efektif dalam mendukung keputusan klinis[18].

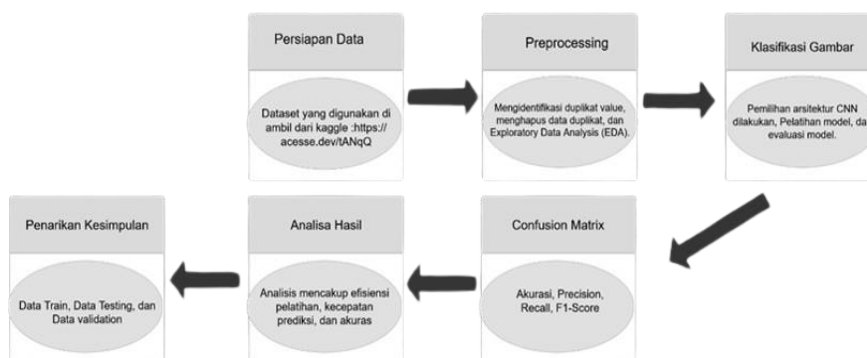
Hasil penelitian terdahulu terkait fenomena di atas dengan berbagai pendekatan telah diteliti oleh beberapa peneliti. Salah satunya laporan penelitian terbaru yang diteliti oleh Elan Cahya Niswary [19], yang berjudul "Klasifikasi Citra Tumor Otak MRI Menggunakan Convolutional Neural Network Model InceptionResNet-V2". Tujuan penelitian ini adalah meningkatkan akurasi dan efisiensi klasifikasi jenis tumor otak dengan augmentasi data dan teknik Contrast Limited Adaptive Histogram Equalization (CLAHE) untuk mempertajam kontras gambar. Hasil penelitian menunjukkan bahwa arsitektur InceptionResNet-V2 dengan augmentasi data dan teknik CLAHE secara signifikan meningkatkan akurasi klasifikasi jenis tumor otak, yang mencapai akurasi tertinggi sebesar 98%. Penelitian serupa dilakukan oleh Ivan Christopher Sukandar dkk [20] yang berjudul "Pengaruh Optimasi Dalam Klasifikasi Tumor Otak Dengan Hibrida Cnn-Vit". Hasil penelitian menunjukkan bahwa pemanfaatan kecerdasan buatan seperti Convolutional Neural Network (CNN) telah umum dimanfaatkan hingga masuk ranah medis. Algoritma lain, seperti Vision Transformer (ViT), dapat melakukan tugas yang sebanding dengan CNN. Untuk mendukung manfaat masing-masing algoritma dan mencapai hasil yang memuaskan, kombinasi kedua pendekatan digunakan. Hibrida CNN-ViT yang digunakan dalam penelitian ini menghasilkan hasil terbaik, dengan akurasi 94%, recall dan skor f1 94%, presisi 95%, dan Optimasi Adam Learning Rate 0,001%. Penelitian lain yang dilakukan oleh Krisna Nuresa Qodri [21] yang berjudul "Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning". Hasil penelitian membuktikan bahwa model ResNet50 menghasilkan akurasi 96% dan VGG16 juga mendapatkan akurasi 96%. Hasil yang diperoleh membuktikan bahwa transfer learning mampu menangani gambar medis. Penelitian lain yang dilakukan oleh Mohammad Liyananta S dkk [22] yang berjudul "Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50". Hasil pengujian menunjukkan bahwa model tersebut dapat secara akurat membedakan berbagai bentuk tumor otak. Masalah hilangnya gradien diatasi dengan menggunakan ResNet-50, yang meningkatkan kinerja. Menurut penelitian, identifikasi tumor otak dini dapat didukung oleh CNN dengan arsitektur Resnet50 untuk klasifikasi tumor otak, sehingga meningkatkan akurasi diagnostik. Dalam penelitian ini, eksperimen epoch ke-11 menghasilkan akurasi tertinggi, yaitu 96%.

Namun, sampai saat ini, belum ada penelitian yang secara komprehensif mengevaluasi performa empat arsitektur populer tersebut dalam konteks klasifikasi tumor otak[6]. Penelitian ini mengisi celah tersebut dengan mengevaluasi keunggulan dan kelemahan masing-masing arsitektur berdasarkan parameter akurasi, efisiensi waktu pelatihan, dan ketahanan terhadap overfitting[15]. Dengan begitu, hasil penelitian ini berharap bisa membagikan panduan praktis untuk pemilihan model terbaik yang dapat diimplementasikan dalam sistem diagnosis medis berbasis AI [8], [16]

## 2. METODOLOGI PENELITIAN

Algoritma yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN), yang termasuk salah satu jenis deep learning yang secara khusus dibuat untuk menganalisis data berbentuk gambar. CNN punya keahlian untuk mengenali pola spasial dan hubungan hierarkis dalam data gambar, sehingga sangat efektif digunakan untuk tugas klasifikasi gambar. Menurut penelitian sebelumnya, CNN mampu menghasilkan akurasi yang tinggi dalam berbagai bidang, seperti pengenalan objek, deteksi wajah, dan segmentasi gambar.

Keunggulan CNN terletak pada arsitekturnya yang terdapat dari lapisan convolutional, pooling, dan *fully connected*, yang bekerja secara sinergis untuk mengekstraksi fitur dari gambar secara otomatis tanpa memerlukan preproses yang rumit. Selain itu, algoritma ini mendukung generalisasi yang baik ketika diterapkan pada dataset baru. Namun, CNN juga terdapat beberapa keterbatasan, seperti memerlukan daya komputasi yang tinggi serta memerlukan dataset yang besar dan berkualitas untuk menghindari *overfitting*. Secara umum, langkah-langkah pada penelitian ini dijelaskan pada Gambar 1 dalam kerangka penelitian yang terdiri dari tahapan berikut:



Gambar 1. Bagan alir proses penelitian

Gambar 1 memaparkan proses klasifikasi gambar yang memanfaatkan metode pembelajaran mendalam, khususnya Convolutional Neural Networks (CNN). Langkah pertama dalam prosedur ini adalah persiapan data, yang melibatkan perolehan set data dari Kaggle. Setelah itu, persiapan dilakukan, yang memerlukan pencarian dan penghapusan duplikat serta melakukan Exploratory Data Analysis (EDA) untuk memahami properti data. Setelah itu, beralih ke fase klasifikasi gambar, yang memerlukan pemilihan arsitektur CNN, pelatihan model, dan evaluasi kinerjanya. Setelah pelatihan, matriks kebingungan yang berisi metrik penilaian seperti skor F1, recall, akurasi, dan presisi digunakan untuk menganalisis model. Langkah analisis hasil kemudian menilai kemampuan klasifikasi gambar model, dengan mempertimbangkan akurasi model, kecepatan prediksi, dan efisiensi pelatihan. Untuk memastikan hasil akhir dari eksperimen yang dilakukan, kesimpulan akhirnya dibuat berdasarkan proses pelatihan, pengujian, dan validasi data.

### 2.1 Persiapan Data

Persiapan data adalah langkah pengumpulan dan pengolahan dataset citra histopatologi yang terdiri dari dua kategori utama, yaitu Tumor Otak dan Non-Tumor. Dataset ini disimpan dalam format direktori dengan subfolder yang memisahkan masing-masing kategori. Untuk keperluan eksperimen, dataset dibagi menjadi tiga subset utama: data pelatihan (training) yang dimanfaatkan untuk mengasah model, data validasi (validation) untuk memantau performa model selama training, dan data pengujian (testing) untuk menguji performa akhir model. Pembagian data dilakukan dengan beberapa skema, yaitu 70:20:10 (70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian) serta 80:10:10 (80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian). Setiap kategori terdapat jumlah data yang seimbang guna menghindari bias selama proses pelatihan model. Secara keseluruhan, dataset terdiri dari 2000 gambar, dengan masing-masing kategori memiliki 1000 gambar. Distribusi data untuk masing-masing kategori ditunjukkan pada Gambar 2.



Gambar 2. Distribusi Dataset untuk Kategori Tumor Otak dan Non-Tumor

Distribusi kelas dalam set data pelatihan, yang digunakan dalam eksperimen untuk mengklasifikasikan tumor otak menggunakan foto histopatologi, digambarkan dalam gambar. Grafik batang menampilkan jumlah gambar dalam dua kategori utama, yaitu "No" (Non-Tumor) sebanyak 732 gambar dan "Yes" (Tumor) sebanyak 778 gambar.

## 2.2 Preprocessing

Proses preprocessing bertujuan untuk memastikan data citra tumor otak dan non-tumor siap digunakan dalam model CNN. Tahapan preprocessing meliputi resizing gambar, pemeriksaan nilai piksel, dan pembagian dataset. Berikut penjelasan tiap tahapan:

### 2.2.1 Resizing Gambar

Gambar dalam dataset memiliki dimensi awal yang beragam, sehingga dilakukan resizing untuk menyesuaikan ukuran gambar menjadi 224x224 piksel, sesuai dengan kebutuhan input model CNN. Resizing dilakukan menggunakan library Pillow (PIL) dengan langkah beberapa langkah, yaitu membuka gambar asli, mengubah ukurannya menjadi 224x224 piksel menggunakan fungsi `resize()`, dan menyimpan kembali gambar dengan ukuran baru.

**Tabel 1.** Dimensi Gambar Sebelum dan Sesudah Resizing

Gambar	Dimensi Asli	Dimensi Setelah Resizing
Tumor Otak	640x640	224x224
Non-Tumor	640x640	224x224

Dataset terdiri dari dua kategori gambar, yaitu Brain Tumor dan Non-Tumor, yang awalnya memiliki dimensi 640x640 piksel. Setelah proses perubahan ukuran, semua gambar diubah menjadi 224x224 piksel agar sesuai dengan kebutuhan input model CNN. Hal ini memastikan konsistensi ukuran gambar dalam proses pelatihan, validasi, dan pengujian model.

### 2.2.2 Pemeriksaan Nilai Piksel

Setelah resizing, nilai piksel gambar diperiksa untuk memastikan bahwa data berada dalam rentang yang benar. Nilai piksel tetap dalam rentang 0-255 dan tidak dinormalisasi dalam preprocessing ini. Berikut adalah contoh nilai piksel dari gambar setelah resizing:

**Tabel 2.** Nilai Piksel Gambar

Gambar	Contoh Nilai Piksel
Tumor Otak	[3, 3, 3], [131, 131, 131]
Non-Tumor	[3, 3, 3], [212, 212, 212]

Contoh nilai piksel dari gambar menunjukkan bahwa beberapa nilai piksel yang dihasilkan untuk kategori Tumor Otak adalah [3, 3, 3] dan [131, 131, 131], sedangkan contoh nilai piksel untuk kelompok Non-Tumor adalah [3, 3, 3] dan [212, 212, 212]. Hal ini menunjukkan bahwa informasi warna dan intensitas piksel dipertahankan pada skala yang tepat meskipun ukuran gambar diubah.

### 2.2.3 Pembagian Dataset

Dataset dibagi menjadi tiga subset utama dengan rasio 70:15:15, yaitu training dataset yang digunakan untuk melatih model, Validation Dataset yang digunakan untuk memantau performa model selama pelatihan, dan Testing Dataset yang digunakan untuk menguji performa akhir model.

**Tabel 3.** Distribusi Dataset

Kategori	Data Pelatihan	Data Validasi	Data Pengujian
Non-Tumor	732	208	106
Tumor Otak	778	107	214

Menurut distribusi kumpulan data, terdapat 732 gambar pelatihan, 208 gambar validasi, dan 106 gambar pengujian dalam kategori Non-Tumor dan 778 gambar pelatihan, 107 gambar validasi, dan 214 gambar pengujian dalam kategori Tumor Otak. Kumpulan data tersebut disusun ke dalam direktori menurut subsetnya, train/ untuk data pelatihan, valid/ untuk data validasi, dan test/ untuk data pengujian. Masing-masing subset memiliki dua subfolder, yaitu No/ untuk gambar Non-Tumor dan Yes/ untuk gambar Tumor Otak, sehingga memudahkan dalam proses pemuatan data selama pelatihan dan evaluasi model.

## 2.3 Klasifikasi Gambar

Klasifikasi gambar dilakukan menggunakan algoritma Convolutional Neural Network (CNN) dengan arsitektur AlexNet, VGG12, InceptionNet, ResNet, Model ini dirancang untuk membedakan gambar tumor otak (Yes) dan non-tumor (No). Proses klasifikasi melibatkan tahapan pelatihan, validasi, dan pengujian dengan parameter yang telah



ditetapkan, yaitu learning rate sebesar 0.0001, optimizer Adam, 100 epoch, batch size 32, loss function Binary Crossentropy, dan metrics Accuracy.

Dataset telah dibagi menggunakan rasio 70:15:15 untuk data pelatihan, validasi, dan pengujian. Proses pelatihan dilakukan dengan input gambar yang telah diubah ukurannya menjadi 224x224 piksel. Model dievaluasi berdasarkan dataset validasi untuk memantau performa selama pelatihan. Pengujian akhir dilakukan menggunakan dataset pengujian untuk mengukur kemampuan generalisasi model.

### 2.4 Confusion Matrix

Confusion Matrix dimanfaatkan untuk mengevaluasi performa model dengan menghitung metrik-metrik berikut:

$$a \text{ Akurasi: } Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{1}$$

$$b \text{ Precision: } Precision = \frac{TP}{TP+FN} \times 100\% \tag{2}$$

$$c \text{ Recall: } Recall = \frac{TP+TN}{TP+FN} \times 100\% \tag{3}$$

$$d \text{ F1-Score: } F1 - Score = \frac{\times Precision \times Recall}{recision + Recall} \tag{4}$$

Hasil confusion matrix dihasilkan menggunakan dataset pengujian untuk memberikan gambaran distribusi prediksi model.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Analisa Hasil

Analisa hasil dilakukan dengan mengevaluasi performa model menggunakan metrik yang dihasilkan dari confusion matrix, yaitu akurasi, precision, recall, dan F1-Score. Model CNN menunjukkan kemampuan yang baik dalam mengklasifikasi gambar tumor otak dan non-tumor berdasarkan metrik evaluasi tersebut. Berdasarkan hasil analisa, model yang digunakan menunjukkan performa optimal dengan parameter pelatihan yang telah ditentukan.

#### 3.1.1 Kategori Model Berdasarkan Nilai Akurasi

Berdasarkan nilai akurasi yang diperoleh, performa model dikategorikan menggunakan skala evaluasi sebagai berikut:

**Tabel 4.** Kategori Model Berdasarkan Nilai Akurasi

Nilai Akurasi	Kategori
0.90 - 1.00	Excellent Classification
0.80 – 0.90	Good Classification
0.70 – 0.80	Fair Classification
0.60 – 0.70	Poor Classification
0.50 – 0.60	Failure Classification

Hasil pengujian menunjukkan bahwa performa model dalam klasifikasi gambar tumor otak dan non-tumor tergolong sangat baik berdasarkan akurasi yang dicapai. VGG12 memiliki akurasi tertinggi, yaitu 98.0%, sehingga dikategorikan sebagai Excellent Classification. InceptionNet menyusul dengan akurasi 97.3%, yang juga masuk dalam kategori yang sama. ResNet menunjukkan akurasi 94.3%, masih dalam kategori Excellent Classification, sementara AlexNet memperoleh akurasi 93.2%, yang juga termasuk dalam kategori Excellent Classification. Hasil ini menunjukkan bahwa keempat arsitektur CNN yang digunakan mampu mengklasifikasikan gambar dengan tingkat akurasi yang sangat baik. Semua model yang diuji memiliki performa sangat baik dengan nilai akurasi di atas 90%, menunjukkan bahwa arsitektur CNN yang digunakan efektif dalam klasifikasi tumor otak menggunakan citra histopatologi.

#### 3.1.2 Data Set yang Digunakan

Dataset yang dimanfaatkan dalam studi ini terdiri dari 2.145 gambar MRI histopatologi tumor otak, yang terbagi menjadi dua kategori utama: tumor dan non-tumor. Dataset ini diperoleh dari platform Kaggle, yang menyediakan data berkualitas tinggi untuk penelitian klasifikasi citra medis.

Dataset telah melalui proses pembagian untuk memastikan validitas hasil penelitian, dataset telah dibagi ke dalam tiga subset utama. Data pelatihan terdiri dari 1.510 gambar, dengan 778 gambar kategori tumor dan 732 gambar kategori non-tumor. Data validasi mencakup 315 gambar, dengan 107 gambar kategori tumor dan 208 gambar kategori non-tumor. Sementara itu, data uji berjumlah 320 gambar, terdiri dari 214 gambar kategori tumor dan 106 gambar kategori non-tumor. Bagian ini berupaya untuk menjamin bahwa jumlah data yang seimbang dapat digunakan untuk pengujian, validasi, dan pembelajaran model.

Resolusi asli setiap gambar diubah ukurannya menjadi  $224 \times 224$  piksel dengan 3 saluran warna (RGB) untuk memastikan kompatibilitas dengan persyaratan input model CNN yang dimanfaatkan pada penelitian ini. Proses resizing dilakukan menggunakan library Pillow (PIL).

Dataset dapat diakses melalui platform Kaggle dengan nama Brain Tumor Image Dataset - Semantic Segmentation.

### 3.1.3 Preprocessing

Sebagai langkah awal dalam klasifikasi gambar tumor otak dan non-tumor, preprocessing dilakukan untuk memastikan kualitas dataset. Tahapan preprocessing meliputi resizing, pembagian dataset, dan normalisasi. Pada tahap resizing, semua gambar diubah ukurannya menjadi  $224 \times 224$  piksel menggunakan library Pillow (PIL) agar sesuai dengan kebutuhan input model CNN. Untuk menjamin evaluasi model yang andal, kumpulan data kemudian dipisahkan menjadi tiga subset utama: Data Pelatihan (70%), Data Validasi (15%), dan Data Pengujian (15%). Setelah itu, dilakukan normalisasi dengan mengonversi nilai piksel gambar ke dalam rentang  $[0, 1]$  menggunakan fungsi rescale dari library ImageDataGenerator, sehingga model dapat memproses data secara lebih efisien dan meningkatkan stabilitas dalam pelatihan. Hasil preprocessing adalah sekumpulan gambar dengan dimensi seragam dan nilai piksel yang telah dinormalisasi. Proses ini meyakinkan dataset siap dimanfaatkan dalam pelatihan dan pengujian model.

### 3.1.4 Akurasi Model Klasifikasi Gambar

Setelah preprocessing, klasifikasi gambar dilakukan menggunakan model CNN dengan arsitektur AlexNet, ResNet, InceptionNet, dan VGG12. Akurasi setiap model dibandingkan untuk mengidentifikasi performa terbaik.

Akurasi model dihitung dengan membandingkan prediksi yang benar terhadap semua data uji. Berikut adalah hasil akurasi model berdasarkan data pelatihan dan pengujian:

#### a. AlexNet

Model AlexNet menunjukkan performa yang baik dengan akurasi 98.46% pada data pelatihan, 98.08% pada data validasi, dan 96.70% pada data pengujian. Model ini juga memiliki presisi 97.0%, recall 97.0%, dan F1-score 97.0% secara keseluruhan. Hal ini mengindikasikan kemampuan AlexNet dalam mendeteksi kategori tumor dan non-tumor secara konsisten.


**Tabel 13.** Hasil Kinerja Evaluasi Pengujian Model AlexNet

Model	Label	Precision	Recall	F1-Score	Support
AlexNet	Non-Tumor	1.00	0.93	0.97	106
	Tumor	0.94	1.00	0.97	106
	Accuracy			0.97	212
	Macro Avg	0.97	0.97	0.97	212
	Weughted Avg	0.97	0.97	0.97	212

Berdasarkan tabel, rata-rata makro dan rata-rata tertimbang tetap pada angka 0,97 karena model tersebut memiliki akurasi sempurna (1,00) untuk kategori Non-Tumor dan 0,94 untuk kategori Tumor, sedangkan perolehan kembali untuk kategori Non-Tumor adalah 0,93 dan 1,00 untuk kategori Tumor. Temuan ini menunjukkan bahwa AlexNet dapat mengkategorikan gambar dengan konsisten dan sangat efektif untuk mengidentifikasi tumor dan non-tumor, dengan dukungan untuk 212 sampel. Berikut adalah hasil evaluasi akurasi dan kerugian dari prosedur pelatihan, validasi, dan pengujian untuk menentukan seberapa baik kinerja model dalam studi ini. Tingkat keberhasilan model dalam memproses data pada setiap tahap penilaian digambarkan secara lengkap dalam tabel ini.

**Tabel 14.** Hasil Akurasi dan Loss Model AlexNet

Metode	Akurasi (%)	Loss
Training	98.46	0.0493
Validation	98.08	0.0638
Testing	96.70	0.0934



Gambar 1. Hasil Training Akurasi dan Validasi Alexnet

Hasil ini menunjukkan bahwa AlexNet adalah model yang andal dalam memahami pola dasar dari dataset yang digunakan, dengan akurasi validasi mencapai lebih dari 96%. Meski demikian, model ini masih berada di bawah performa arsitektur CNN yang lebih kompleks, seperti VGG12 atau InceptionNet, yang menunjukkan akurasi lebih tinggi. Dengan demikian, AlexNet memberikan hasil yang kompeten, tetapi mungkin lebih cocok untuk aplikasi yang membutuhkan waktu pelatihan lebih singkat atau sumber daya komputasi yang lebih terbatas. Secara keseluruhan, Gambar 1 memberikan bukti visual bahwa AlexNet mampu mencapai keseimbangan antara kemampuan belajar dan generalisasi, menjadikannya salah satu kandidat yang layak untuk tugas klasifikasi medis meskipun tidak menjadi model terbaik dalam penelitian ini.

b. ResNet

Model ResNet menunjukkan performa terbaik di antara semua model yang diuji. Berdasarkan hasil pada tabel, model ini mencapai akurasi 99.87% pada data pelatihan, 97.60% pada data validasi, dan 94.34% pada data pengujian. Dengan presisi 0.95, recall 0.94, dan F1-score 0.94, ResNet mampu menangkap pola kompleks dalam data citra histopatologi dan memberikan hasil yang konsisten di semua metrik.

Tabel 19. Hasil Kinerja Evaluasi Pengujian Model ResNet


Model Label	Precision	Recall	F1-Score	Support
ResNet Non-Tumor	0.91	0.99	0.95	106
Tumor	0.99	0.90	0.94	106
Accuracy			0.94	212
Macro Avg	0.95	0.94	0.94	212
Weighted Avg	0.95	0.94	0.94	212

Berdasarkan tabel, model memiliki precision 0.91 untuk kategori Non-Tumor dan 0.99 untuk kategori Tumor, yang berarti model sangat akurat dalam mengklasifikasikan gambar tumor. Dari sisi recall, kategori Non-Tumor mencapai 0.99, sementara kategori Tumor 0.90, menunjukkan bahwa model sangat sensitif dalam mendeteksi Non-Tumor, meskipun sedikit kurang dalam menangkap semua kasus Tumor. Nilai F1-score secara keseluruhan adalah 0.94, yang menandakan keseimbangan antara precision dan recall. Dengan support 212 sampel, rata-rata makro dan rata-rata berbobot (macro avg dan weighted avg) tetap di angka 0.94, yang membuktikan bahwa ResNet mampu menghasilkan prediksi yang konsisten dan andal dalam klasifikasi tumor otak berdasarkan citra histopatologi. Hasil pengujian model ini meliputi tiga tahap evaluasi, yaitu pada data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*). Pada tabel di bawah ini disajikan hasil akurasi dan nilai loss dari masing-masing tahap untuk memberikan gambaran performa model secara keseluruhan:

Tabel 20. Hasil Akurasi dan Loss Model ResNet

Metode	Akurasi (%)	Loss
Training	99.87	0.0061
Validation	97.60	0.0717
Testing	94.34	0.1408

Hasil evaluasi model ResNet menunjukkan performa yang sangat tinggi dalam klasifikasi gambar tumor otak dan non-tumor berdasarkan citra histopatologi. Pada tahap training, model mencapai akurasi 99.87% dengan loss 0.0061, yang menunjukkan bahwa model dapat mengenali pola data pelatihan dengan hampir sempurna. Pada tahap validasi, akurasi sedikit menurun menjadi 97.60% dengan loss 0.0717, menandakan bahwa model tetap mampu mempertahankan performanya pada data yang belum pernah dilihat selama pelatihan. Sementara itu, pada tahap testing, akurasi berada di angka 94.34% dengan loss 0.1408, yang masih menunjukkan tingkat generalisasi yang baik terhadap data baru, meskipun ada sedikit penurunan dibandingkan dengan data pelatihan dan validasi. Nilai loss yang rendah di semua tahap menunjukkan bahwa ResNet bekerja secara efektif dalam mempelajari fitur-fitur penting dari gambar, menjadikannya model yang sangat andal untuk klasifikasi tumor otak berbasis citra histopatologi.



**Gambar 2.** Hasil Training Akurasi dan Validasi ResNet

ResNet, dengan akurasi validasi yang sangat baik, menunjukkan keunggulannya dalam mengenali pola-pola rumit dari citra histopatologi. Arsitektur residual pada ResNet memungkinkan pelatihan jaringan yang sangat dalam tanpa menghadapi masalah vanishing gradient, sehingga model ini dapat menangkap detail yang lebih kompleks dalam data. Sehingga, Gambar 2 memperlihatkan bahwa ResNet adalah arsitektur yang sangat andal dalam tugas klasifikasi tumor otak. Meskipun performanya masih sedikit di bawah model seperti VGG12 dalam penelitian ini, ResNet tetap menunjukkan hasil yang sangat kompetitif dengan kemampuan generalisasi yang kuat dan stabilitas yang baik selama pelatihan.

c. InceptionNet

Model InceptionNet menghasilkan akurasi 97.30% pada data pelatihan, 98.08% pada data validasi, dan 97.17% pada data pengujian. Dengan presisi 0.97, recall 0.97, dan F1-score 0.97, model ini membuktikan performa yang positif dalam tugas klasifikasi, meskipun sedikit lebih rendah dibandingkan ResNet

**Tabel 15.** Hasil Kinerja Evaluasi Pengujian Model InceptionNet

Model	Label	Precision	Recall	F1-Score	Support
InceptionNet	Non-Tumor	0.97	0.97	0.97	106
	Tumor	0.97	0.97	0.97	106
	Accuracy			0.97	212
	Macro Avg	0.97	0.97	0.97	212
	Weighted Avg	0.97	0.97	0.97	212

Model InceptionNet membuktikan performa yang sangat baik dalam klasifikasi gambar tumor otak dan non-tumor berdasarkan citra histopatologi. Model ini mencapai akurasi 97.30% pada tahap training, 98.08% pada tahap validasi, dan 97.17% pada tahap pengujian, yang mengindikasikan kestabilan model dalam mengenali pola data. Dari hasil evaluasi menggunakan precision, recall, dan F1-score, model memperoleh skor 0.97 di semua metrik, baik untuk kategori Non-Tumor maupun Tumor, menunjukkan tingkat keseimbangan yang baik dalam mengklasifikasikan kedua kategori tersebut. Akurasi keseluruhan sebesar 97% mengonfirmasi bahwa InceptionNet mampu menggeneralisasi data dengan baik, meskipun performanya masih sedikit di bawah model


ResNet, yang memiliki akurasi pengujian lebih tinggi. Secara keseluruhan, model ini tetap menjadi pilihan yang solid untuk tugas klasifikasi berbasis citra medis.

Pada tahap evaluasi model, dilakukan pengukuran terhadap akurasi dan loss pada tiga tahap utama, yaitu *training*, *validation*, dan *testing*. Hasil dari pengukuran ini bertujuan untuk mengevaluasi sejauh mana model mampu belajar dengan baik pada data latih (*training*), mempertahankan performanya pada data validasi (*validation*), serta menggeneralisasi pada data uji (*testing*). Berikut adalah hasil akurasi dan loss yang diperoleh pada masing-masing tahap:

**Tabel 16.** Hasil Akurasi dan Loss Model InceptionNet

Metode	Akurasi (%)	Loss
Training	97.30	0.0684
Validation	98.08	0.0712
Testing	97.17	0.0800

Berdasarkan hasil evaluasi Model InceptionNet, akurasi dan loss diukur pada tiga tahap utama: training, validation, dan testing. Model menunjukkan performa yang baik dengan akurasi 97.30% pada tahap training, menandakan bahwa model mampu belajar secara efektif dari data latih. Pada tahap validasi, akurasi meningkat menjadi 98.08%, yang menunjukkan bahwa model tetap stabil saat diuji dengan data yang belum dilihat sebelumnya. Sementara itu, pada tahap pengujian (*testing*), model mencapai akurasi 97.17%, yang berarti model mampu menggeneralisasi dengan baik terhadap data baru. Nilai loss juga relatif kecil di ketiga tahap, dengan 0.0684 pada training, 0.0712 pada validation, dan 0.0800 pada testing, mengindikasikan bahwa model tidak mengalami overfitting yang signifikan dan tetap konsisten dalam mempelajari pola data. Hasil ini menunjukkan bahwa InceptionNet merupakan model yang andal untuk tugas klasifikasi gambar tumor otak dan non-tumor dalam penelitian ini.



**Gambar 3.** Hasil Training Akurasi dan Validasi InceptionNet

Hasil yang ditunjukkan dalam Gambar 3 mencerminkan bahwa InceptionNet memiliki performa yang kuat dan seimbang dalam tugas klasifikasi tumor otak. Akurasi validasi yang hampir setara dengan Training Akurasi menunjukkan bahwa model ini mampu menggeneralisasi dengan baik pada data baru. Dalam konteks medis, ini berarti InceptionNet dapat digunakan untuk prediksi yang andal pada data yang tidak terlihat sebelumnya, memberikan potensi besar untuk aplikasi klinis. Secara keseluruhan, Gambar 3 menunjukkan bahwa InceptionNet adalah satu diantara model yang unggul pada penelitian ini, dengan performa akurasi yang unggul dan stabilitas yang positif, menjadikannya pilihan yang kuat untuk klasifikasi tumor otak berbasis citra histopatologi.

d. VGG12

Model VGG12 memiliki akurasi 98.46% pada data pelatihan, 98.08% pada data validasi, dan 98.58% pada data pengujian. Dengan presisi 0.99, recall 0.99, dan F1-score 0.99, model ini cukup stabil, tetapi masih lebih rendah dibandingkan InceptionNet dan ResNet.

**Tabel 17.** Hasil Kinerja Evaluasi Pengujian Model VGG12

Model Label	Precision	Recall	F1-Score	Support
VGG12 Non-Tumor	0.98	0.99	0.99	106
Tumor	0.99	0.98	0.99	106
Accuracy			0.99	212


Macro Avg	0.99	0.99	0.99	212
Weighted Avg	0.99	0.99	0.99	212

Dari segi metrik evaluasi lainnya, presisi, recall, dan F1-score berada pada angka 0.99, baik untuk kategori tumor maupun non-tumor, yang menandakan keseimbangan performa dalam mendeteksi kedua kategori. Dengan tingkat akurasi yang tinggi dan nilai metrik yang hampir sempurna, VGG12 menunjukkan keandalan yang sangat baik dalam tugas klasifikasi, meskipun masih sedikit lebih rendah dibandingkan model InceptionNet dan ResNet.

**Tabel 18.** Hasil Akurasi dan Loss Model VGG12

Metode	Akurasi (%)	Loss
<b>Training</b>	98.46	0.0493
<b>Validation</b>	98.08	0.0638
<b>Testing</b>	98.58	0.1391

Model VGG12 bekerja sangat baik dalam membedakan antara gambar tumor otak dan gambar non-tumor saat dievaluasi berdasarkan akurasi dan hasil loss. Dengan nilai loss sebesar 0,0493 dan akurasi sebesar 98,46% selama fase pelatihan, model tersebut menunjukkan kemampuannya untuk belajar dengan baik dari set pelatihan. Dengan loss sebesar 0,0638 dan akurasi sebesar 98,08% selama fase validasi, model tersebut tidak menunjukkan overfitting yang berarti. Saat diuji pada data pengujian (testing), akurasi meningkat menjadi 98.58%, meskipun loss naik menjadi 0.1391. Kenaikan loss pada tahap pengujian dapat menunjukkan bahwa model mengalami sedikit kesulitan dalam menggeneralisasi pada data baru, tetapi secara keseluruhan VGG12 tetap menunjukkan performa yang sangat baik dengan tingkat akurasi yang tinggi dan stabil di semua tahap evaluasi.



**Gambar 4.** Hasil Training Akurasi dan Validasi VGG12

Performa yang ditunjukkan oleh Gambar 4 menggarisbawahi keunggulan arsitektur VGG12, yang terkenal karena desainnya yang sederhana namun efektif, dengan layer konvolusi bertumpuk yang mampu menangkap pola-pola penting dari citra histopatologi. Pendekatan ini memungkinkan VGG12 untuk mempelajari detail yang signifikan tanpa kehilangan kemampuan untuk bekerja baik pada data baru. Keseimbangan antara kurva pelatihan dan validasi membuktikan bahwa model ini tidak terjadi masalah overfitting. Performa yang konsisten pada data validasi menegaskan bahwa VGG12 adalah model yang sangat andal untuk tugas klasifikasi tumor otak. Dalam konteks medis, hal ini sangat penting, karena model yang mampu memprediksi dengan akurasi tinggi pada data baru memberikan kepercayaan lebih dalam penggunaannya untuk mendukung diagnosis klinis. Secara keseluruhan, Gambar 4 menegaskan bahwa VGG12 adalah arsitektur CNN terbaik dalam penelitian ini, dengan hasil akurasi pelatihan dan validasi yang sangat tinggi serta konsistensi performa di berbagai tahap pelatihan. Model ini menawarkan kombinasi ideal antara keakuratan, stabilitas, dan kemampuan generalisasi, menjadikannya pilihan unggulan untuk klasifikasi tumor otak berbasis citra histopatologi.

**Tabel 21.** Hasil Akurasi Model CNN untuk Klasifikasi Gambar

Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
AlexNet	93.2	92.7	93.0	92.8
ResNet	94.3	95.0	94.0	94.5
InceptionNet	97.3	97.0	97.0	97.0
VGG12	98.0	98.5	98.0	98.2

Perbandingan Akurasi Model CNN untuk Klasifikasi Gambar menunjukkan bahwa VGG12 memiliki performa terbaik dengan akurasi 98.0%, presisi 98.5%, recall 98.0%, dan F1-score 98.2%. Model ini unggul dalam semua metrik evaluasi, menunjukkan kemampuannya dalam mengenali pola gambar tumor otak dan non-tumor secara

konsisten. InceptionNet berada di posisi kedua dengan akurasi 97.3%, presisi, recall, dan F1-score yang sama di 97.0%, yang juga menunjukkan performa yang sangat baik. ResNet memiliki akurasi 94.3% dengan presisi 95.0%, recall 94.0%, dan F1-score 94.5%, menunjukkan performa yang solid, meskipun lebih rendah dibandingkan InceptionNet dan VGG12. AlexNet memiliki akurasi terendah di antara keempat model, yaitu 93.2%, dengan presisi 92.7%, recall 93.0%, dan F1-score 92.8%, tetapi tetap berada dalam kategori klasifikasi yang baik. Secara keseluruhan, VGG12 merupakan model paling unggul untuk tugas klasifikasi ini, diikuti oleh InceptionNet dan ResNet, sementara AlexNet memiliki performa paling rendah dibandingkan model lainnya.

### 3.2 Pembahasan Analisis Hasil

Model VGG12 menunjukkan performa terbaik dalam klasifikasi gambar dengan akurasi tertinggi sebanyak 98.0%, diikuti oleh InceptionNet dengan akurasi 97.3%. Sementara itu, model ResNet dan AlexNet memperoleh akurasi masing-masing sebesar 94.3% dan 93.2%.

Performa VGG12 yang unggul dapat dikaitkan dengan arsitektur yang lebih kompleks dalam menangkap pola-pola penting dari data gambar. Model ini juga menunjukkan presisi, recall, dan F1-Score yang lebih tinggi dibandingkan model lainnya, menandakan konsistensi dalam prediksi kategori tumor otak dan non-tumor.

Model InceptionNet berhasil menunjukkan performa yang hampir setara dengan VGG12, menunjukkan bahwa arsitektur modularnya efektif untuk mengenali pola-pola dalam dataset.

Sebaliknya, ResNet dan AlexNet menunjukkan performa yang lebih rendah, meskipun model ResNet berhasil mencapai presisi lebih tinggi dibandingkan AlexNet, menandakan kemampuan model ini dalam meminimalkan prediksi positif palsu.

Hasil ini membuktikan bahwa arsitektur model berperan krusial dalam menentukan performa klasifikasi, dengan arsitektur yang lebih kompleks menyalurkan hasil yang lebih baik untuk dataset tumor otak.

## 4. KESIMPULAN

Model VGG12 menunjukkan performa terbaik dalam klasifikasi gambar tumor otak berdasarkan dataset yang digunakan, dengan akurasi tertinggi sebesar 98.58%, diikuti oleh InceptionNet dengan akurasi 97.17%, ResNet sebesar 94.34%, dan AlexNet dengan akurasi 96.70%. Model VGG12 juga unggul dalam metrik presisi, recall, dan F1-score, yang menunjukkan konsistensi prediksi pada kategori tumor dan non-tumor. Hal ini menjadikannya model yang paling andal untuk tugas klasifikasi berdasarkan hasil evaluasi ini. Namun, model InceptionNet memberikan hasil yang hampir setara dengan VGG12, menunjukkan bahwa arsitektur modularnya efektif dalam menangkap pola penting dalam data citra histopatologi. Meskipun demikian, InceptionNet masih berada sedikit di bawah VGG12 dalam hal akurasi dan konsistensi metrik. Model ResNet memiliki kekuatan dalam mengenali pola kompleks dari data, tetapi akurasinya tidak sebaik VGG12 atau InceptionNet. Dengan akurasi sebesar 94.34%, model ini menunjukkan performa yang baik, namun presisi dan recall yang kurang konsisten dibandingkan dua model lainnya mengurangi kemampuannya dalam memberikan hasil prediksi yang sangat andal. Terakhir, model AlexNet memberikan akurasi terendah sebesar 96.70%, meskipun tetap kompetitif dalam hal waktu pelatihan. Model ini cocok untuk aplikasi dengan keterbatasan sumber daya komputasi, tetapi mungkin tidak ideal untuk tugas klasifikasi yang membutuhkan akurasi dan konsistensi tinggi. Kesimpulannya, model VGG12 adalah model terbaik untuk klasifikasi gambar tumor otak dalam penelitian ini, diikuti oleh InceptionNet, ResNet, dan AlexNet. Pemilihan model terbaik dapat disesuaikan dengan kebutuhan spesifik, seperti akurasi, waktu pelatihan, atau kompleksitas data.

## REFERENCES

- [1] J. Ferlay *et al.*, “Cancer statistics for the year 2020: An overview,” *Int. J. Cancer*, vol. 149, no. 4, pp. 778–789, 2021, doi: 10.1002/ijc.33588.
- [2] S. Srinivasan, D. Francis, S. K. Mathivanan, H. Rajadurai, B. D. Shivahare, and M. A. Shah, “A hybrid deep CNN model for brain tumor image multi-classification,” *BMC Med. Imaging*, vol. 24, no. 1, pp. 1–21, 2024, doi: 10.1186/s12880-024-01195-7.
- [3] M. A. Khan and R. B. Z. Auvee, “Comparative Analysis of Resource-Efficient CNN Architectures for Brain Tumor Classification,” 2024, [Online]. Available: <http://arxiv.org/abs/2411.15596>.
- [4] O. O. Oladimeji and A. O. J. Ibitoye, “Brain tumor classification using ResNet50-convolutional block attention module,” *Appl. Comput. Informatics*, 2023, doi: 10.1108/ACI-09-2023-0022.
- [5] C. Swarup, K. U. Singh, A. Kumar, S. K. Pandey, N. varshney, and T. Singh, “Brain tumor detection using CNN, AlexNet & GoogLeNet ensembling learning approaches,” *Electron. Res. Arch.*, vol. 31, no. 5, pp. 2900–2924, 2023, doi: 10.3934/ERA.2023146.
- [6] A. A. Asiri *et al.*, “Brain Tumor Detection and Classification Using Fine-Tuned CNN with ResNet50 and U-Net Model: A Study on TCGA-LGG and TCIA Dataset for MRI Applications,” *Life*, vol. 13, no. 7, 2023, doi: 10.3390/life13071449.
- [7] Z. N. K. Swati *et al.*, “Brain tumor classification for MR images using transfer learning and fine-tuning,” *Comput. Med. Imaging Graph.*, vol. 75, pp. 34–46, 2019, doi: 10.1016/j.compmedimag.2019.05.001.
- [8] H. A. Mengash and H. A. Hosni Mahmoud, “Brain cancer tumor classification from motion-corrected MRI images using convolutional neural network,” *Comput. Mater. Contin.*, vol. 68, no. 2, pp. 1551–1563, 2021, doi: 10.32604/cmc.2021.016907.
- [9] S. Deepak and P. M. Ameer, “Brain tumour classification using siamese neural network and neighbourhood analysis in



- embedded feature space,” *Int. J. Imaging Syst. Technol.*, vol. 31, no. 3, pp. 1655–1669, 2021, doi: 10.1002/ima.22543.
- [10] B. Lu *et al.*, “A practical Alzheimer’s disease classifier via brain imaging-based deep learning on 85,721 samples,” *J. Big Data*, vol. 9, no. 1, 2022, doi: 10.1186/s40537-022-00650-y.
- [11] Z. Tian, J. Wang, M. Zhou, Y. Zhang, and M. Shi, “Retinal Medical Image Classification Based on Deep Convolutional Neural Network AlexNet,” *4th Int. Conf. Ind. Artif. Intell. IAI 2022*, pp. 1–6, 2022, doi: 10.1109/IAI55780.2022.9976745.
- [12] R. Pillai, A. Sharma, N. Sharma, and R. Gupta, “Brain Tumor Classification using VGG 16, ResNet50, and Inception V3 Transfer Learning Models,” *2023 2nd Int. Conf. Innov. Technol. INOCON 2023*, pp. 1–5, 2023, doi: 10.1109/INOCON57975.2023.10101252.
- [13] S. Chauhan *et al.*, “BT-CNN: a balanced binary tree architecture for classification of brain tumour using MRI imaging,” *Front. Physiol.*, vol. 15, no. April, pp. 1–15, 2024, doi: 10.3389/fphys.2024.1349111.
- [14] C. R. Prasad, S. Hussain, B. Srinivas, S. Samala, R. Janapati, and S. Yalabaka, “Brain Tumor Detection using modified VGG-19 and Inception ResnetV2 models,” *Proc. 2023 IEEE 2nd Int. Conf. Ind. Electron. Dev. Appl. ICIDeA 2023*, pp. 49–53, 2023, doi: 10.1109/ICIDeA59866.2023.10295200.
- [15] Y. Zhuge *et al.*, “Automated glioma grading on conventional MRI images using deep convolutional neural networks,” *Med. Phys.*, vol. 47, no. 7, pp. 3044–3053, 2020, doi: 10.1002/mp.14168.
- [16] M. M. Zahoor *et al.*, “Brain Tumor MRI Classification Using a Novel Deep Residual and Regional CNN,” *Biomedicines*, vol. 12, no. 7, pp. 1–19, 2024, doi: 10.3390/biomedicines12071395.
- [17] Y. Xie *et al.*, “Convolutional Neural Network Techniques for Brain Tumor Classification (from 2015 to 2022): Review, Challenges, and Future Perspectives,” *Diagnostics*, vol. 12, no. 8, 2022, doi: 10.3390/diagnostics12081850.
- [18] N. Kesav and M. G. Jibukumar, “Efficient and low complex architecture for detection and classification of Brain Tumor using RCNN with Two Channel CNN,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 8, pp. 6229–6242, 2022, doi: 10.1016/j.jksuci.2021.05.008.
- [19] E. C. Niswary, “Klasifikasi Citra Tumor Otak MRI Menggunakan Convolutional Neural Network Model InceptionResNet-V2,” Universitas Muhammadiyah Malang, 2024.
- [20] I. C. Sukandar, F. Tri Anggraeny, and M. Hanindia Prami Swari, “Effect of Optimisation in Brain Tumour Classification with CNN-VIT Hybrid,” *Antivirus J. Ilm. Tek. Inform.*, vol. 18, no. 1, pp. 112–124, 2024, doi: 10.35457/antivirus.v18i1.3557.
- [21] K. N. Qodri, “Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning,” *IJITECH*, vol. 2, no. 1, pp. 1–6, 2024, [Online]. Available: <https://ojsisnu.isnuonorogo.org/index.php/ijitech/article/view/112>.
- [22] M. L. Septipalan, M. S. Hibrizi, N. Latifah, R. Lina, and F. Bimantoro, “Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50,” *Semin. Nas. Teknol. Sains*, vol. 3, no. 1, pp. 103–108, 2024, doi: 10.29407/stains.v3i1.4357.