

STUDI LITERATUR : PERBANDINGAN ARSITEKTUR CNN UNTUK KLASIFIKASI TUMOR OTAK

Luvenia Andrius Lukman, Evans Fuad

Teknik Informatika, Universitas Muhammadiyah Riau
Jalan KH. Ahmad Dahlan No.88 Riau, Indonesia
220401097@student.umri.ac.id

ABSTRAK

Perkembangan *Convolutional Neural Network* (CNN) telah membawa kemajuan signifikan dalam analisis citra medis, khususnya pada klasifikasi tumor otak berbasis citra MRI. Namun, menentukan arsitektur CNN yang paling tepat tetap menjadi tantangan utama karena performa setiap model sangat dipengaruhi oleh karakteristik data dan ketersediaan sumber daya komputasi. Penelitian ini bertujuan untuk melakukan analisis komparatif sistematis terhadap implementasi serta kinerja berbagai arsitektur CNN dalam tugas klasifikasi tumor otak. Metode yang digunakan adalah *Systematic Literature Review* (SLR) dengan protokol PRISMA terhadap 20 artikel ilmiah dari Google Scholar dan Garuda yang diterbitkan antara tahun 2022 hingga 2025. Hasil penelitian menunjukkan bahwa Custom CNN merupakan pendekatan yang paling banyak diterapkan (9 studi), diikuti oleh ResNet dan VGG. ResNet secara konsisten memberikan akurasi tertinggi hingga mencapai 99,8% pada dataset kompleks. Sementara itu, arsitektur seperti *EfficientNet* dan *MobileNet* menawarkan performa kompetitif dengan kebutuhan komputasi yang lebih rendah. Pemilihan arsitektur yang optimal sangat bergantung pada karakteristik dataset dan ketersediaan sumber daya komputasi yang tersedia

Kata Kunci: *Convolutional Neural Network, MRI Brain Tumor, Deep Learning, Literature Review, Transfer Learning, Medical Image Classification.*

1. PENDAHULUAN

Perkembangan teknologi Deep Learning (DL), khususnya Convolutional Neural Network (CNN), telah mentransformasi paradigma dalam analisis citra medis, menjadikannya pilar penting dalam sistem diagnosis berbantuan komputer (Computer-Aided Diagnosis/CAD). Kemampuan CNN untuk secara otomatis mengekstraksi dan mempelajari pola visual yang kompleks mulai dari fitur sederhana hingga representasi tingkat tinggi dari data mentah telah memberikan dampak besar pada deteksi dan klasifikasi berbagai penyakit [1]. Dalam bidang pencitraan medis, khususnya Magnetic Resonance Imaging (MRI) untuk diagnosis tumor otak, CNN menawarkan solusi otomatis yang sangat dibutuhkan untuk mengatasi volume data yang terus meningkat. MRI menghasilkan citra beresolusi tinggi dengan detail struktur jaringan lunak yang superior, menjadikannya modalitas yang ideal. Namun, analisis manual citra MRI yang masif oleh tenaga medis sering kali memakan waktu, rentan terhadap variasi subjektif, dan dapat terbebani oleh kompleksitas anatomi otak [2].

Di sinilah peran arsitektur CNN modern, seperti VGG, ResNet, DenseNet, Inception, dan EfficientNet, menjadi krusial. Sejak keberhasilan arsitektur awal, inovasi dalam desain jaringan telah berfokus pada peningkatan akurasi sekaligus menjaga efisiensi komputasi. Arsitektur-arsitektur ini memperkenalkan konsep-konsep kunci seperti residual connection (pada ResNet) untuk mengatasi masalah vanishing gradient pada jaringan dalam, dense connectivity (pada DenseNet) untuk memaksimalkan feature reuse, dan mekanisme multi-scale feature extraction (pada Inception) untuk menangkap konteks pada berbagai

ukuran. Namun, performa setiap arsitektur tidaklah universal. Pemilihan arsitektur yang optimal sangat dipengaruhi oleh karakteristik data, kompleksitas tugas klasifikasi (misalnya, membedakan antara jenis tumor yang berbeda), dan ketersediaan sumber daya komputasi [3][4].

Menentukan arsitektur CNN yang paling tepat dan stabil untuk klasifikasi tumor otak berbasis MRI tetap menjadi tantangan utama. Model yang sangat dalam (misalnya, ResNet-152) mungkin memberikan akurasi tertinggi, tetapi memerlukan sumber daya komputasi yang besar dan rentan terhadap overfitting pada dataset medis yang sering kali berukuran terbatas. Sebaliknya, arsitektur yang lebih ringan dan efisien (misalnya, EfficientNet) menawarkan kecepatan inferensi, tetapi mungkin mengorbankan kemampuan tangkap fitur yang kaya pada citra medis yang detail. Variabilitas ini menggarisbawahi perlunya kajian komparatif yang sistematis untuk mengevaluasi secara mendalam kelebihan, kekurangan, dan performa relatif arsitektur-arsitektur terkemuka dalam konteks diagnosis tumor otak [5].

Berdasarkan latar belakang tersebut, penelitian ini disusun sebagai Studi Literatur Sistematis (SLR) untuk menganalisis dan membandingkan implementasi serta kinerja berbagai arsitektur CNN dalam tugas klasifikasi tumor otak berbasis citra MRI. Fokus utama penelitian ini adalah untuk menjawab beberapa pertanyaan penelitian utama, yaitu mengidentifikasi arsitektur CNN yang paling umum dan sering digunakan dalam klasifikasi tumor otak berbasis MRI, membandingkan performa arsitektur-arsitektur tersebut berdasarkan temuan dari berbagai penelitian yang telah dipublikasikan sebelumnya ,

serta mengevaluasi kelebihan dan kekurangan utama yang dimiliki oleh masing-masing arsitektur CNN dalam konteks diagnosa medis tersebut.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Ketepatan diagnosis dini menjadi faktor penentu dalam memperpanjang harapan hidup pasien tumor otak, mengingat risiko kerusakan fungsi motorik dan kognitif yang ditimbulkannya. Di tengah tingginya beban kerja tenaga medis, kehadiran deep learning dalam pengolahan citra MRI menawarkan solusi krusial untuk menekan risiko kesalahan diagnosis manusia. Makalah ini melakukan pembedahan secara sistematis terhadap 60 artikel ilmiah yang terbit sejak 2020 hingga Januari 2024. Penekanan utama diberikan pada efektivitas metode modern seperti transfer learning, autoencoders, transformers, hingga attention mechanisms. Melalui analisis komparatif atas kelebihan dan batasan yang ditemukan, studi ini memetakan arah riset di masa depan sekaligus berfungsi sebagai referensi rujukan bagi para praktisi dan akademisi dalam menyempurnakan teknologi klasifikasi tumor otak otomatis.[6]

2.2. Tumor Otak

Tumor otak adalah pertumbuhan sel abnormal di jaringan otak yang dapat bersifat jinak maupun ganas. Jenis tumor seperti *glioma*, *meningioma*, dan *pituitary tumor* memiliki karakteristik bentuk dan lokasi berbeda sehingga memerlukan proses diagnosis yang akurat. Tantangan utama dalam identifikasi tumor terletak pada variasi ukuran, tekstur, serta batas tumor yang tidak selalu terlihat jelas, sehingga dibutuhkan dukungan metode analisis berbasis komputer untuk membantu dokter melakukan penilaian secara konsisten [6].

2.3. MRI

Magnetic Resonance Imaging (MRI) merupakan teknik pencitraan yang banyak digunakan untuk mendeteksi kelainan otak karena mampu menghasilkan citra dengan resolusi tinggi dan kontras jaringan yang baik tanpa radiasi. MRI menyediakan beberapa sekuens seperti T1, T2, dan FLAIR yang memberi informasi berbeda mengenai struktur otak. Variasi sekuens ini memungkinkan proses identifikasi tumor dilakukan dengan lebih detail[6].

2.4. Deep Learning pada Citra Medis

Deep learning memainkan peran penting dalam analisis citra medis karena mampu mengekstraksi fitur langsung dari data tanpa memerlukan perancangan fitur manual. Model-model *deep learning* terbukti mampu mengenali pola kompleks pada citra medis yang sulit dideteksi dengan metode tradisional. Dalam penelitian tumor otak, *deep learning* membantu proses klasifikasi menjadi lebih cepat, objektif, dan akurat, terutama saat menangani dataset berskala besar dengan variasi intensitas dan bentuk [7].

2.5. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan kelas algoritma Deep Learning yang paling efektif dan dominan dalam menganalisis data visual, seperti citra Magnetic Resonance Imaging (MRI). CNN dirancang untuk meniru proses visual korteks pada otak manusia, memungkinkan model untuk secara otomatis dan hirarkis mempelajari representasi fitur spasial dari data input [5].

Arsitektur CNN pada dasarnya terdiri dari dua bagian utama, yaitu ekstraksi fitur (feature extraction) dan klasifikasi (classification).

Bagian Ekstraksi Fitur dibangun dari lapisan-lapisan utama yang berulang, yaitu:

a. Lapisan Konvolusi

(Convolutional Layer - Conv): Lapisan ini menerapkan serangkaian filter (kernel) untuk melakukan operasi konvolusi pada citra input. Tujuan dari operasi ini adalah untuk mendeteksi fitur lokal, seperti tepi, sudut, dan tekstur, dan menghasilkan Peta Fitur (Feature Map).

b. Fungsi Aktivasi


(Activation Function - ReLU): Umumnya, fungsi aktivasi non-linier seperti Rectified Linear Unit (ReLU) diterapkan setelah konvolusi untuk memperkenalkan non-linieritas ke dalam model, memungkinkan pemetaan input ke output yang lebih kompleks.

c. Lapisan Pooling

Lapisan ini berfungsi untuk mengurangi dimensi spasial dari peta fitur, sehingga mengurangi kompleksitas komputasi dan jumlah parameter yang dibutuhkan. Max Pooling adalah metode yang paling umum digunakan karena dapat mempertahankan informasi fitur yang paling dominan di setiap region [8].

Bagian Klasifikasi terdiri dari:

Lapisan Fully Connected (FC): Peta fitur yang telah diratakan (flattened) dimasukkan ke dalam lapisan FC, yang bertindak sebagai classifier akhir untuk memetakan fitur yang terdeteksi ke label kelas yang spesifik [8].




Gambar 1. Arsitektur cnn sequential (cnn dasar)

2.6. Arsitektur CNN untuk Klasifikasi Tumor Otak

Berbagai arsitektur CNN telah dikembangkan oleh peneliti untuk meningkatkan akurasi klasifikasi, stabilitas model, dan efisiensi komputasi. Beberapa arsitektur yang paling sering digunakan dalam penelitian tumor otak antara lain:

2.7. VGGNet (Visual Geometry Group Network)

VGGNet merupakan salah satu arsitektur CNN klasik yang menggunakan susunan layer konvolusi kecil berukuran 3×3 secara berturut-turut. Keunggulan VGG terletak pada strukturnya yang sederhana dan mudah dianalisis, namun jumlah parameternya sangat besar sehingga membutuhkan memori tinggi. Pada penelitian citra MRI, VGG banyak digunakan sebagai baseline karena stabil dan mudah diimplementasikan [9].




Gambar 2. Arsitektur vggnet

Gambar 2 menggambarkan arsitektur lengkap VGG-19 yang terdiri dari 19 lapisan trainable, dimulai dari input citra 224×224×3 yang diproses melalui lima blok konvolusi berurutan masing-masing diakhiri max-pooling dengan konfigurasi 64, 128, 256, dan dua blok 512 filter kemudian hasil ekstraksi fitur diratakan dan diteruskan ke tiga lapisan Fully Connected berukuran 4096–4096–1000 sebelum akhirnya diklasifikasikan menggunakan Softmax.

2.8. ResNet (Residual Network)

ResNet memperkenalkan konsep *residual connection* yang memungkinkan jaringan sangat dalam tanpa mengalami degradasi performa. Struktur ini membuat ResNet lebih efisien dalam mempelajari fitur kompleks dan sering memberikan akurasi tinggi pada dataset medis. Model seperti ResNet-50 dan ResNet-101 terbukti efektif dalam klasifikasi tumor otak karena dapat menangkap variasi fitur lebih baik [10].




Gambar 3. Arsitektur resnet

Gambar 3 menunjukkan arsitektur ResNet50 yang memproses input melalui tahap awal berupa padding, convolution, batch normalization, ReLU, dan max-pooling, lalu melewati lima stage berisi rangkaian convolutional block dan identity block dengan jalur skip connection khas ResNet, sebelum akhirnya melalui average pooling, flattening, dan fully connected layer untuk menghasilkan output klasifikasi.

2.9. DenseNet (Densely Connected Convolutional Networks)

DenseNet menghubungkan setiap layer dengan seluruh layer sebelumnya dalam satu block. Mekanisme ini membuat proses propagasi fitur lebih kaya dan memperbaiki aliran gradien sehingga pelatihan lebih stabil. DenseNet biasanya memiliki parameter lebih sedikit dibandingkan arsitektur lain dengan kedalaman serupa, dan sering menunjukkan performa unggul pada dataset MRI yang relatif kecil [11].




Gambar 4. Arsitektur densenet

Gambar 4 menggambarkan alur dasar pemrosesan fitur pada DenseNet, di mana input melewati Batch Normalization dan aktivasi ReLU sebelum diproses oleh convolution 3×3 untuk menghasilkan keluaran dengan k channel.

2.10. Inception

Inception menggunakan konsep *multi-scale feature extraction*, yaitu memproses citra melalui beberapa filter ukuran berbeda secara paralel. Strategi ini membuat model lebih fleksibel dalam mengenali pola tumor yang ukurannya bervariasi [12].




Gambar 5. Arsitektur inception

Gambar 5 menunjukkan struktur Inception module yang memproses input secara paralel melalui jalur 1×1, 3×3, 5×5 convolution, dan 3×3 max-pooling, lalu menggabungkan seluruh output melalui filter concatenation untuk menghasilkan representasi fitur multi-skala dalam satu tahap.

2.11. EfficientNet

EfficientNet mengusung pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan. Arsitektur ini dikenal efisien dan mampu menghasilkan akurasi tinggi dengan jumlah parameter lebih sedikit dibanding model besar lainnya. Pada klasifikasi tumor otak, EfficientNet sering

unggul dalam kasus dataset terbatas karena lebih mudah beradaptasi dan tidak cepat *overfitting* [13].



Gambar 6. Arsitektur efficientnet

Gambar 6 memvisualisasikan komponen utama arsitektur CNN meliputi lapisan konvolusi untuk deteksi pola, pooling untuk reduksi dimensi, serta aktivasi dan fully connected layer untuk klasifikasi yang bekerja secara terintegrasi memproses citra input menjadi prediksi akhir.

3. METODE PENELITIAN

Pada bagian ini memuat metode yang digunakan pada pembuatan Kerja Praktek. Penelitian ini menggunakan pendekatan Systematic Literature Review (SLR) untuk mengkaji secara komprehensif perkembangan arsitektur Convolutional Neural Network (CNN) yang diterapkan dalam klasifikasi tumor otak berdasarkan citra Magnetic Resonance Imaging (MRI). Prosedur dilakukan mengikuti alur PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses)

3.1. Strategi Pencarian dan Sumber Data

Proses tinjauan literatur dimulai dengan perumusan fokus kajian yang jelas. Sumber literatur utama yang digunakan adalah Google Scholar dan Garuda (Garba Rujukan Digital), yang dipilih karena menyediakan cakupan luas terhadap jurnal ilmiah terindeks nasional (SINTA) dan internasional. Strategi pencarian dirancang secara terstruktur menggunakan kombinasi kata kunci ("CNN" OR "Convolutional Neural Network") AND ("MRI" OR "Magnetic Resonance Imaging").

Kriteria Inklusi yang diterapkan pada tahap awal pencarian adalah:

- Batasan Tahun: Publikasi yang diterbitkan antara 2022 hingga 2025.
- Jenis Publikasi: Artikel Jurnal.
- Indeks Jurnal: Jurnal minimal terindeks SINTA (untuk publikasi nasional) atau memiliki indeks kredibel lainnya (untuk publikasi internasional).

3.2. Tahapan Seleksi Literatur (Filtering)

Seluruh publikasi yang diperoleh dari tahap pencarian disaring melalui proses bertahap, untuk menjamin relevansi dan kualitas.

- Tahap Identifikasi: Melakukan pencarian awal menggunakan sintaks kata kunci di Google Scholar dan Garuda.
- Tahap Penyaringan Judul dan Abstrak (Screening): Dokumen yang teridentifikasi

disaring berdasarkan relevansi judul dan abstrak untuk memastikan fokus utama penelitian adalah pada klasifikasi tumor otak berbasis MRI menggunakan arsitektur CNN.

- Tahap Evaluasi Teks Lengkap (Eligibility): Artikel yang lolos screening kemudian diunduh dan dievaluasi teks lengkapnya (full-text). Pada tahap ini, hanya artikel yang memenuhi kriteria metodologis (memiliki deskripsi metode CNN yang jelas) dan kriteria tematik (menyajikan hasil perbandingan atau performa akurasi klasifikasi tumor otak) yang dipertahankan.

3.3. Analisis Data dan Sintesis

Setiap artikel yang terpilih dianalisis secara mendalam melalui ekstraksi data terstruktur. Komponen utama yang diekstraksi dari setiap studi meliputi:

- Arsitektur CNN: Identifikasi arsitektur utama yang digunakan (misalnya, VGG-16, ResNet-50, DenseNet-121, InceptionV3, EfficientNet).
- Karakteristik Dataset: Sumber data, ukuran, dan jenis tumor yang diklasifikasikan.
- Teknik Preprocessing: Metode yang digunakan untuk normalisasi, segmentasi, atau augmentasi citra.
- Metrik Evaluasi: Nilai performa yang dilaporkan (misalnya, Accuracy, Precision, Recall, F1-Score, dan AUC).

4. HASIL DAN PEMBAHASAN

4.1. Hasil

Kajian ini berhasil mengidentifikasi 20 artikel yang memenuhi kriteria inklusi dan relevan dengan topik klasifikasi tumor otak berbasis citra MRI menggunakan arsitektur Convolutional Neural Network (CNN). Setiap studi dianalisis berdasarkan tahun publikasi, jenis arsitektur CNN yang digunakan, serta performa model yang dilaporkan. Secara umum, temuan menunjukkan bahwa berbagai arsitektur baik Custom CNN, model transfer learning seperti ResNet, VGG, MobileNet, Inception, EfficientNet, maupun pendekatan hibrida menampilkan variasi kinerja yang cukup signifikan. Sebagian besar penelitian berbasis Custom CNN mampu mencapai akurasi tinggi, terutama ketika dikombinasikan dengan teknik augmentasi dan preprocessing yang optimal. Arsitektur ResNet secara konsisten menunjukkan performa unggul pada dataset kompleks, dengan beberapa penelitian mencapai akurasi lebih dari 95%. MobileNet, VGG, dan EfficientNet memberikan hasil yang kompetitif meskipun cenderung lebih ringan secara komputasi. Selain itu, pendekatan hibrida seperti kombinasi CNN dengan Genetic Algorithm atau transformasi wavelet juga menunjukkan hasil yang sangat baik pada beberapa studi spesifik.

Table 1. Ringkasan Penelitian Arsitektur CNN untuk Klasifikasi Tumor Otak

No.	Judul	Tahun	Arsitektur CNN	Hasil
1	Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network [14]	2024	Custom CNN	Model terbaik (augmentasi <i>flipping</i> dan <i>scale</i>) menghasilkan akurasi 92,97%
2	Evaluasi Teknik Augmentasi Data Untuk Klasifikasi Tumor Otak Menggunakan CNN Pada Citra MRI [15]	2024	Custom CNN	Teknik augmentasi <i>penskalaan</i> dan <i>flip vertikal/horizontal</i> memberikan rata-rata akurasi 92,97%, dengan akurasi maksimal mencapai 100% pada <i>epoch</i> ke-20.
3	Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma [16]	2023	MobileNetV2	Dari hasil pengujian dengan data testing didapat nilai evaluasi akurasi sebesar 0.7833 atau 78% dan hasil pengujian dengan data validasi didapat nilai evaluasi akurasi sebesar 0.83 atau 83%
4	Analisis Kinerja Arsitektur CNN Alexnet dan VGG16 untuk Klasifikasi Tumor Otak [17]	2025	Alexnet dan VGG16	Alexnet memberikan akurasi pengujian sebesar 78.99% dengan F1-score tertimbang 0.79, sedangkan VGG16 memperoleh akurasi sebesar 78.01% dengan F1-score 0.75.
5	Medical image classification of brain tumor using convolutional neural network algorithm [18]	2023	Custom CNN	Hasil penelitian ini memperoleh nilai akurasi sebesar 84%.
6	Development of Deep Learning Model Based on Convolutional Neural Network (CNN) for Brain Tumor Classification Using MRI Images [19]	2025	Custom CNN	Model mencapai akurasi keseluruhan sebesar 96% dengan skor F1 yang tinggi.
7	Klasifikasi Citra Tumor Otak Menggunakan Teknik Transfer Learning pada Arsitektur ResNet-50 [9]	2025	ResNet-50	Hasil menunjukkan bahwa model dengan freeze 15 layer memberikan akurasi lebih tinggi sebesar 91,86% dibandingkan freeze 30 layer sebesar 90,88%.
8	Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network [20]	2024	Custom CNN dengan 2 Skema	Evaluasi F1-Score model skema 1 dan skema 2 berturut-turut: 96% dan 98%, sedangkan nilai Accuracy 98% dan 99%.
9	Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network [21]	2023	Inception, ResNet-50, dan VGG16	Arsitektur ResNet50 memiliki akurasi tertinggi sebesar 94.1%.
10	Penerapan Convolutional Neural Network (CNN) dalam Klasifikasi Citra MRI untuk Deteksi Tumor Otak Manusia [22]	2023	EfficientNetB3	Hasil penelitian menunjukkan bahwa model EfficientNetB3 mencapai akurasi keseluruhan sebesar 86%,
11	Algoritma Convolutional Neural Network sebagai Alat Bantu Analisa Tingkat Keparahan Tumor Otak [12]	2024	Custom CNN, Resnet-152, dan VGG-16	Hasilnya menunjukkan bahwa ketiga model dapat melakukan klasifikasi tumor dengan akurasi masing-masing sebesar 84%, 95% dan 84% pada data tanpa augmentasi dan 49%, 81% dan 72% untuk data yang mengalami augmentasi.
12	Klasifikasi Jenis Tumor Otak pada Citra MRI Menggunakan Convolutional Neural Network (CNN) [23]	2025	Custom CNN, SVM dan MobileNetV2	Hasil menunjukkan akurasi model CNN Dasar sebesar 97,18%, lebih unggul dibanding metode baseline seperti SVM (90,7%) dan MobileNetV2 (94,6%)
13	A deep learning based system for accurate diagnosis of brain tumors using T1-w MRI [24]	2022	ResNet50	Model yang diusulkan mencapai akurasi tertinggi 99,8% dan kesalahan optimal 0,005 saat menggunakan Adam dibandingkan dengan enam arsitektur CNN terkenal lainnya.
14	Brain tumor classification in magnetic resonance imaging images using convolutional neural network [10]	2022	Custom CNN	Mendapatkan akurasi yang baik sebesar 98,27%, yang melebihi model-model lain yang sudah ada.

No.	Judul	Tahun	Arsitektur CNN	Hasil
15	Brain tumor segmentation using double density dual tree complex wavelet transform combined with convolutional neural network and genetic algorithm [25]	2022	Hibrida DDDTCWT, CNN, dan Genetic Algorithm (GA) (<i>Segmentation</i>)	Hasil penelitian menunjukkan bahwa kombinasi DDDTCWT, CNN, dan GA dapat digunakan untuk menganalisis gambar MRI otak dan menghasilkan nilai parameter lebih dari 95%.
16	Deteksi Tumor Otak pada Citra Magnetic Resonance Imaging (MRI) Menggunakan Arsitektur MobileNet dengan Optimizer Adam [26]	2025	MobileNetV1 dan MobileNetV2	MobileNetV1 dengan <i>optimizer</i> Adam mencapai akurasi, presisi, <i>recall</i> , dan F1-score sebesar 96,5%. MobileNetV2 mencapai akurasi 86%.
17	High precision brain tumor classification model based on deep transfer learning and stacking concepts [27]	2022	7 Pre-trained CNN (VGG16, VGG19, IncepResNet V2, Xception, Inception V3, MobileNet, DenseNet)	Ketepatan tes sebesar 98,67%, skor F1 rata-rata sebesar 98,62%, ketepatan tes rata-rata sebesar 98,06%, dan sensitivitas tes rata-rata sebesar 98,33%.
18	Penerapan Deep Learning pada Sistem Klasifikasi Tumor Otak Berbasis Citra CT Scan [11]s	2024	DenseNet	Hasil evaluasi menunjukkan bahwa model mencapai akurasi tertinggi sebesar 0.92 pada epoch 100,
19	Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning[13]	2024	VGG16 dan ResNet50	Hasil menunjukkan bahwa model ResNet50 mendapatkan akurasi 96% dan VGG16 juga mendapatkan akurasi 96%.
20	Klasifikasi Tumor Otak Berbasis MRI Menggunakan Algoritma Convolutional Neural Network [28]	2024	Alexnet	Hasil penelitian diperoleh akurasi sebesar 0,9642.

4.2. RQ1: Arsitektur CNN apa saja yang paling umum dan sering digunakan dalam klasifikasi tumor otak berbasis citra MRI?

Berdasarkan ekstraksi data dari 20 studi terpilih, ditemukan bahwa pendekatan Custom CNN (arsitektur yang dirancang sendiri dari awal) merupakan metode yang paling banyak diterapkan, diikuti oleh arsitektur transfer learning populer seperti ResNet dan VGG. Rincian distribusi penggunaan arsitektur disajikan pada Tabel 2.

Table 2. Distribusi Frekuensi Arsitektur CNN dalam Klasifikasi Tumor Otak

Peringkat	Arsitektur CNN	Frekuensi (Jumlah Studi)	Referensi Studi
1	Custom CNN	9	[11], [13], [15], [16], [19], [20], [21], [24], [26]
2	ResNet (ResNet50, ResNet152)	6	[10], [13], [14], [22], [25], [28]
3	VGG (VGG16, VGG19)	5	[13], [14], [18], [22], [28]
4	MobileNet (V1, V2)	4	[17], [24], [27], [28]
5	Inception	2	[22], [28]
6	AlexNet	2	[18], [29]
7	DenseNet	2	[12], [28]
8	EfficientNet	1	[23]

4.3. Q2: Bagaimana perbandingan performa arsitektur-arsitektur tersebut menurut penelitian yang telah dilakukan sebelumnya?

Berdasarkan sintesis terhadap 20 studi yang dianalisis, performa arsitektur CNN dalam tugas klasifikasi tumor otak menunjukkan variasi yang cukup lebar, dengan akurasi terendah berada pada kisaran 78% dan tertinggi mencapai 99,8%. Variasi ini dipengaruhi oleh jenis arsitektur, konfigurasi model, teknik augmentasi, serta kualitas dataset yang digunakan masing-masing peneliti. Tabel 3 berikut merangkum perbandingan performa antar arsitektur yang paling sering digunakan.

Table 3. Perbandingan Performa Arsitektur CNN

Kelompok Arsitektur	Rentang Akurasi (Min – Max)	Rata-rata Estimasi	Referensi Studi
ResNet (<i>ResNet50</i> , <i>ResNet152</i>)	90,88% – 99,80%	~ 95,5%	[10], [13], [14], [22], [25]
Custom CNN	84,00% – 99,00%	~ 93,8%	[11], [15], [16], [19], [20], [21], [24]
VGG (<i>VGG16</i> , <i>VGG19</i>)	78,01% – 96,00%	~ 87,0%	[13], [14], [18], [22]
MobileNet (<i>V1</i> , <i>V2</i>)	78,33% – 96,50%	~ 88,4%	[17], [24], [27]
AlexNet, DenseNet, EfficientNet	78,99% – 96,42%	~ 89,0%	[12], [18], [23], [29]

4.4. RQ3: Apa kelebihan dan kekurangan masing-masing arsitektur dalam konteks klasifikasi tumor otak?

Berdasarkan analisis terhadap literatur yang ditinjau, setiap arsitektur CNN memiliki karakteristik unik yang memengaruhi performanya dalam tugas klasifikasi tumor otak berbasis citra MRI. Secara umum, arsitektur yang lebih dalam seperti ResNet dan DenseNet mampu menangkap representasi fitur yang lebih kompleks sehingga memberikan akurasi yang tinggi.

Namun, peningkatan kedalaman jaringan tidak selalu sejalan dengan efisiensi komputasi, dan pada dataset medis yang terbatas, jaringan yang sangat dalam lebih rentan terhadap overfitting. Sebaliknya, arsitektur yang lebih ringan seperti MobileNet atau EfficientNet menawarkan efisiensi komputasi dan waktu inferensi yang lebih cepat, tetapi dalam beberapa studi menunjukkan kemampuan ekstraksi fitur yang kurang optimal untuk citra MRI yang memiliki detail anatomi tinggi.

Sementara itu, arsitektur klasik seperti VGG tetap banyak digunakan karena kesederhanaan strukturnya, namun jumlah parameternya yang besar membuatnya boros memori. Model custom CNN cenderung menunjukkan performa kompetitif karena dapat disesuaikan dengan karakteristik dataset tertentu, meskipun kualitasnya sangat bergantung pada desain arsitektur oleh peneliti. Secara keseluruhan, kelebihan dan kekurangan tiap arsitektur menunjukkan bahwa tidak ada satu model yang unggul secara universal, dan pemilihan arsitektur yang optimal harus mempertimbangkan kompleksitas data, ukuran dataset, dan kebutuhan komputasi.

5. KESIMPULAN DAN SARAN

Hasil sintesis literatur menunjukkan bahwa Custom CNN merupakan arsitektur yang paling banyak digunakan, disusul oleh ResNet, VGG, dan MobileNet. Perbandingan performa dari 20 studi menampilkan rentang akurasi yang cukup bervariasi (78%–99,8%), dengan ResNet umumnya memberikan hasil paling konsisten. Analisis kelebihan dan kekurangan tiap arsitektur mengindikasikan bahwa model dalam seperti ResNet unggul pada ekstraksi fitur kompleks tetapi membutuhkan komputasi lebih besar, sedangkan arsitektur ringan seperti MobileNet lebih efisien namun kurang optimal untuk detail citra MRI tertentu. Tidak ada arsitektur yang unggul secara universal, sehingga pemilihan model harus disesuaikan dengan karakteristik data dan kebutuhan komputasi. Disarankan untuk mengevaluasi model berbasis transformer, menguji dataset multi-institusi yang lebih beragam, menerapkan augmentasi dan regularisasi lanjutan, serta memasukkan metode interpretabilitas agar model lebih dapat diandalkan dalam konteks klinis.

DAFTAR PUSTAKA

[1] D. L. Tyas, F. R. Rumambi, A. Patanduk, R. C.

Johanes, J. K. Unsrat, and S. Utara, "Klasifikasi Jenis Tumor Otak Melalui Citra MRI dengan Menggunakan Convolutional Neural Network," *IFTK*, vol. 4221, no. April, pp. 26–34, 2025.

- [2] J. Hossain, "Streamlining Brain Tumor Classification with Custom Transfer Learning in MRI Images," *Indones. J. Comput. Sci.*, vol. 1, no. 1, 2023.
- [3] V. Ainunnikmah, N. Aini, R. A. Putri, and F. Soffiani, "Brain tumor classification using CNN Klasifikasi tumor otak menggunakan CNN," *J. Komput. dan Teknol. Inf.*, vol. 1, no. 2, pp. 70–73, 2025, doi: 10.26714/jkti.v3i1.13957.
- [4] D. C. F, G. Wibisono, M. A. F, and M. Afrad, "Transfer Learning model Convolutional Neural Network menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI," *LEDGER J. Inform. Inf. Technol.*, vol. 8798, no. 1, 2024.
- [5] G. A. N. Savarimuthu, "A novel lightweight CNN design for MRI brain tumor image classification with performance - driven optimization," *Discov. Comput. Res.*, vol. 1, no. 1, 2025.
- [6] S. Bouhafra and H. El Bahi, "Deep Learning Approaches for Brain Tumor Detection and Classification Using MRI Images (2020 to 2024): A Systematic Review," *J. Imaging Informatics Med.*, vol. 1, no. 1, pp. 1403–1433, 2025, doi: 10.1007/s10278-024-01283-8.
- [7] S. Chauhan *et al.*, "BT-CNN : a balanced binary tree architecture for classification of brain tumour using MRI imaging," *Frontiers (Boulder)*, vol. 1, no. April, pp. 1–15, 2024, doi: 10.3389/fphys.2024.1349111.
- [8] A. W. Reza *et al.*, "applied sciences A CNN-Based Strategy to Classify MRI-Based Brain Tumors Using Deep Convolutional Network," *Appl. Sci.*, vol. 1, no. 1, 2023.
- [9] Y. I. Salsabila, H. Mustofa, and M. A. Ulinuha, "TEKNIK TRANSFER LEARNING PADA ARSITEKTUR RESNET-50," *JISICOM*, vol. 9, no. 1, pp. 128–139, 2025, doi: 10.52362/jisicom.v9i1.1925.
- [10] N. Remzan, K. Tahiry, and A. Farchi, "Brain tumor classification in magnetic resonance imaging images using convolutional neural network," *Int. J. Electr. Comput. Eng.*, vol. 12, no. 6, pp. 6664–6674, 2022, doi: 10.11591/ijece.v12i6.pp6664-6674.
- [11] B. Agustina and A. R. Isnain, "Penerapan Deep Learning pada Sistem Klasifikasi Tumor Otak Berbasis Citra CT Scan," *Indones. J. Comput. Sci.*, vol. 13, no. 1, pp. 4557–4565, 2024.
- [12] J. T. Manik and F. Haryanto, "Algoritma Convolutional Neural Network sebagai Alat Bantu Analisa Tingkat Keparahan Tumor Otak," *MIND (Multimedia Artif. Intell. Netw. Database) J.*, vol. 9, no. 1, pp. 1–12, 2024.
- [13] K. N. Qodri, "Analisis Perbandingan Klasifikasi

- Tumor Otak Menggunakan Deep Learning,” *Indones. J. Inf. Technol.*, vol. 1, no. 1, pp. 1–6, 2024.
- [14] D. Husen, “Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network,” *Bit-Tech*, vol. 7, no. 1, 2024, doi: 10.32877/bt.v7i1.1576.
- [15] D. Husen, “Evaluasi teknik augmentasi data untuk klasifikasi tumor otak menggunakan cnn pada citra mri,” *TEKNIMEDIA*, vol. 1, no. 1, pp. 219–228, 2023.
- [16] A. N. Nafisa *et al.*, “Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma , Pituitary dan Meningioma,” *J. Teknol. Informasi, Komput. dan Apl.*, vol. 5, no. 1, pp. 53–61, 2023.
- [17] A. Diah *et al.*, “ANALISIS KINERJA ARSITEKTUR CNN ALEXNET DAN VGG16,” *JUTIK J. Teknol. Inf. dan Komput.*, vol. 11, no. 2, pp. 278–286, 2025.
- [18] A. Muis and A. Yudhana, “Medical image classification of brain tumor using convolutional neural network algorithm,” *INFOTEL*, vol. 15, no. 3, pp. 227–232, 2023.
- [19] M. Rani, T. Sinaga, B. Tampubolon, N. H. Daulay, and D. Triana, “Development of Deep Learning Model Based on Convolutional Neural Network (CNN) for Brain Tumor Classification Using MRI Images,” *EduMatika*, vol. 5, no. 2, pp. 27–34, 2025, doi: 10.30596/jcositte.v1i1.xxxx.
- [20] H. Fakhri, T. Badriyah, I. Syarif, and R. Sigit, “Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network,” *INOVTEK Polbeng - Seri Inform.*, vol. 9, no. 1, pp. 65–79, 2024.
- [21] R. Wardhani, T. Informatika, U. I. Lamongan, and J. Timur, “Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network,” *J. Inform. J. Pengemb. IT*, vol. 8, no. 3, pp. 213–219, 2023.
- [22] D. Lizard, S. Dimara, S. W. Putri, and R. Amelia, “Penerapan Convolutional Neural Network (CNN) dalam Klasifikasi Citra MRI untuk Deteksi Tumor Otak Manusia,” *KERNEL*, vol. 4, no. 2, pp. 70–77, 2023, doi: 10.31284/j.kernel.2023.v4i2.6960.
- [23] A. R. Alam, M. S. WD, A. F. Nduru, R. Rosnelly, and A. Setiawan, “Klasifikasi Jenis Tumor Otak pada Citra MRI Menggunakan Convolutional Neural Network (CNN),” *REMIK*, vol. 9, no. 4, pp. 1396–1404, 2025.
- [24] M. Ahmed, F. Khalifa, H. E. Moustafa, G. A. Saleh, and E. Abdelhalim, “A deep learning based system for accurate diagnosis of brain tumors using T1-w MRI,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 28, no. 2, pp. 1192–1202, 2022, doi: 10.11591/ijeecs.v28.i2.pp1192-1202.
- [25] R. S. Samosir, E. Abdurachman, F. L. Gaol, and B. S. Sabarguna, “Brain tumor segmentation using double density dual tree complex wavelet transform combined with convolutional neural network and genetic algorithm,” *IAES Int. J. Artif. Intell.*, vol. 11, no. 4, pp. 1373–1383, 2022, doi: 10.11591/ijai.v11.i4.pp1373-1383.
- [26] M. Z. Basri, M. G. Somoal, and R. S. Aji, “Deteksi Tumor Otak pada Citra Magnetic Resonance Imaging (MRI) Menggunakan Arsitektur MobileNet dengan Optimizer Adam,” *Tek. Inform.*, vol. 5, no. 2, 2025.
- [27] H. El Hamdaoui, A. Benfares, S. Boujraf, N. El, H. Chaoui, and B. Alami, “High precision brain tumor classification model based on deep transfer learning and stacking concepts,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 24, no. 1, pp. 167–177, 2021, doi: 10.11591/ijeecs.v24.i1.pp167-177.
- [28] F. C. R, F. Indriyani, I. R. Rahadjeng, U. Bina, and S. Informatika, “Klasifikasi Tumor Otak Berbasis Magnetic Resonance Menggunakan Algoritma Convolutional Neural Network,” *Digit. Transform. Technol.*, vol. 3, no. 2, pp. 918–924, 2023.