

Systematic Review: Pemanfaatan Deep Learning untuk Diagnosis Penyakit Menggunakan MRI

Nova Nova^{*1}, Aisyah Mulyanti², Cantika Silmy Aulia Putri Burhanie³, Ledistia Mulyani⁴, Ridha Ghina Nurjanah⁵, Widya Utami⁶, Nunung Siti Sukaesih⁷

^{1,2,3,4,5,6,7}Program Studi Profesi Ners Kampus Sumedang, Universitas Pendidikan Indonesia, Indonesia
Email: ¹nova@upi.edu

Abstrak

Seiring dengan pesatnya perkembangan teknologi, kecerdasan buatan (*Artificial Intelligence/AI*) mulai digunakan dalam dunia medis untuk membantu analisis citra medis, termasuk MRI. Tujuan dari penelitian ini adalah untuk menyajikan analisis komprehensif mengenai pemanfaatan CNN dalam diagnosis penyakit menggunakan MRI. Penelitian ini adalah *rapid review* yang menggunakan strategi pencarian di database seperti Google Scholar, PubMed, dan Scopus dengan kata kunci *deep learning*, *diagnose*, dan *medical image*, serta seleksi artikel berdasarkan kriteria inklusi dan eksklusi. Hasil penelitian menunjukkan bahwa CNN dapat meningkatkan akurasi diagnosis penyakit melalui MRI, dengan tingkat akurasi berkisar antara 73,6% hingga 98,7%. Model seperti 3D CNN dan U-Net terbukti efektif dalam mendeteksi dan mengklasifikasikan berbagai penyakit. Kesimpulannya adalah CNN memberikan hasil yang menjanjikan dalam analisis MRI, meningkatkan akurasi dan efisiensi diagnosis. Meskipun masih ada tantangan seperti kebutuhan data berkualitas tinggi dan validasi klinis, AI berpotensi besar merevolusi dunia medis.

Kata Kunci: *Citra Medis, Deep Learning, Diagnosis*

Abstract

With the rapid advancement of technology, Artificial Intelligence (AI) has begun to be utilized in the medical field to assist in medical image analysis, including MRI. The aim of this study is to present a comprehensive analysis of the utilization of Convolutional Neural Networks (CNN) in disease diagnosis using MRI. This study is a rapid review that employs a search strategy in databases such as Google Scholar, PubMed, and Scopus using keywords like deep learning, diagnosis, and medical imaging, along with article selection based on inclusion and exclusion criteria. The findings indicate that CNN can improve disease diagnosis accuracy through MRI, with accuracy rates ranging from 73.6% to 98.7%. Models such as 3D CNN and U-Net have been proven effective in detecting and classifying various diseases. In conclusion, CNN provides promising results in MRI analysis, enhancing the accuracy and efficiency of diagnosis. Although challenges remain, such as the need for high-quality data and clinical validation, AI holds great potential to revolutionize the medical field.

Keywords: *Deep Learning, Diagnose, Medical Image*

1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) di bidang kesehatan telah mengalami kemajuan pesat, salah satunya dalam teknologi citra medis. Kemampuan AI dalam mengidentifikasi berbagai objek dalam pencitraan medis secara otomatis semakin meningkat, memungkinkan analisis yang lebih cepat dan akurat dalam mendeteksi kelainan atau penyakit (Arabahmadi & Farahbakhsh, 2022). AI adalah cabang ilmu computer yang berfokus pada pengembangan kemampuan mesin atau komputer sehingga mampu menjalankan berbagai tugas layaknya manusia, dengan tingkat keakuratan dan efisiensi yang setara atau bahkan lebih unggul (Farwati et al., 2023).

Seiring dengan pesatnya perkembangan teknologi, kecerdasan buatan (*Artificial Intelligence/AI*) mulai digunakan dalam dunia medis untuk membantu dalam mendiagnosis penyakit mengalami peningkatan yang signifikan secara global. Pada tahun 2021, nilai pasar pelayanan berbasis AI mencapai

\$11 miliar dan diproyeksikan meningkat menjadi \$187 miliar pada tahun 2030 (IBM, 2023). Berdasarkan studi penelitian yang telah dilakukan menunjukkan bahwa AI memiliki tingkat akurasi yang tinggi dalam mendiagnosis berbagai penyakit. Sebuah *meta-analysis* yang melibatkan lebih dari 152.000 gambar slide digital menunjukkan sensitivitas rata-rata sebesar 96,3% dan spesifisitas sebesar 93,3% dalam deteksi penyakit menggunakan AI (McGenity et al., 2023).

Di Indonesia, pemanfaatan AI dalam diagnosis penyakit juga semakin berkembang. Teknologi seperti stetoskop pintar berbasis AI telah diperkenalkan untuk meningkatkan akurasi diagnosis penyakit jantung dengan menganalisis data dari suara jantung secara *real-time* (Rokom, 2024). Selain itu, AI digunakan dalam menganalisis citra medis, termasuk MRI. *Magnetic Resonance Imaging* (MRI) merupakan salah satu teknik pencitraan medis yang memiliki peranan penting dalam dunia kesehatan. MRI digunakan secara luas dalam mendiagnosis berbagai penyakit, mulai dari gangguan neurologis seperti Alzheimer dan Parkinson, hingga penyakit kardiovaskular dan kanker (Hussain et al., 2020). Berbeda dengan teknik pencitraan lain seperti CT-Scan atau sinar-X, MRI tidak menggunakan radiasi ionisasi sehingga lebih aman untuk pasien. Namun, proses interpretasi gambar MRI sering kali kompleks dan membutuhkan keahlian tinggi dari tenaga medis, terutama radiolog. Tingkat akurasi diagnosis juga sangat bergantung pada pengalaman serta kemampuan individu dalam mengenali pola yang muncul dalam gambar hasil pemindaian (Hidayatullah, 2024).

Salah satu cabang AI yang menunjukkan perkembangan signifikan adalah *deep learning*, sebuah teknik pembelajaran mesin berbasis jaringan saraf tiruan (*artificial neural networks*) yang mampu mengidentifikasi pola kompleks secara otomatis. Salah satu pendekatan yang paling banyak digunakan dalam *deep learning* untuk analisis MRI adalah *Convolutional Neural Network* (CNN). CNN memiliki keunggulan dalam mengenali pola nonlinear yang kompleks dari citra MRI, sehingga sangat efektif dalam mengekstraksi fitur dari gambar MRI untuk keperluan diagnosis (Hidayatullah, 2024).

Berbagai penelitian telah menunjukkan bahwa penerapan CNN dalam analisis MRI dapat meningkatkan akurasi diagnosis, seperti studi oleh Li et al., (2024) menggunakan arsitektur Xception untuk klasifikasi gambar yang lebih akurat dan efisien pada MRI dalam mendiagnosis Alzheimer, dengan akurasi mencapai 99,6%. Studi lain oleh Brima et al., (2022) mengembangkan *Deep Transfer Learning* menggunakan CNN dengan arsitektur ResNet50 yang digunakan untuk pengenalan gambar MRI otak, mencapai akurasi hingga 97,05%. Selain itu, penelitian oleh Nayan et al., (2023) menunjukkan bahwa arsitektur CNN dengan lima lapisan konvolusi dapat mendeteksi tumor otak dengan akurasi hingga 98,6%.

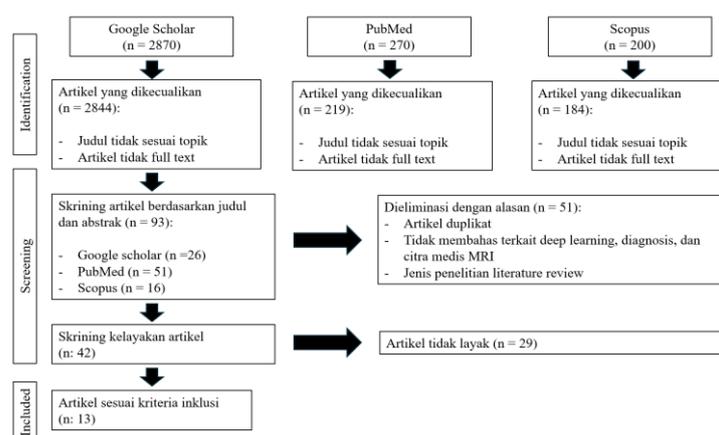
Sebagian besar penelitian sebelumnya lebih berfokus pada penggunaan model CNN konvensional seperti VGG-16 dan ResNet50. Namun, penelitian ini meninjau berbagai pendekatan yang lebih kompleks, seperti PCNN dan CVG-Net, yang menggabungkan teknik transfer learning dan optimasi fitur. Beberapa studi sebelumnya hanya membahas satu jenis citra MRI (misalnya otak atau tulang belakang), sementara penelitian ini membandingkan berbagai pendekatan CNN untuk berbagai aplikasi MRI, termasuk deteksi tumor otak, segmentasi jaringan, dan klasifikasi penyakit. Studi sebelumnya sering kali hanya melaporkan akurasi model tanpa membahas faktor yang memengaruhi performa, seperti kualitas dataset, kebutuhan komputasi, serta keterbatasan model dalam lingkungan klinis. Penelitian ini menyoroti aspek-aspek tersebut untuk memberikan gambaran yang lebih komprehensif. Penelitian ini tidak hanya meninjau efektivitas model CNN tetapi juga membandingkannya dengan penelitian terdahulu, memberikan insight lebih dalam tentang tren teknologi terbaru dalam diagnosis berbasis MRI.

Berdasarkan uraian di atas, penelitian ini bertujuan untuk menyajikan analisis komprehensif mengenai pemanfaatan CNN dalam diagnosis penyakit menggunakan MRI. Dengan melakukan tinjauan terhadap berbagai studi yang telah dilakukan sebelumnya, penelitian ini akan memberikan gambaran menyeluruh tentang tren perkembangan teknologi *deep learning* dalam analisis MRI. Fokus utama akan diberikan pada penelitian ini adalah bagaimana akurasi CNN dalam mendiagnosis penyakit menggunakan MRI, kecepatan, kemudahan dalam penggunaan alatnya serta *cost effectiveness* dari metode tersebut. Dengan demikian, penelitian ini diharapkan dapat menjadi landasan bagi penelitian berikutnya dan membantu dalam pengembangan sistem berbasis AI yang lebih akurat dan efisien untuk digunakan dalam dunia medis.

2. METODE PENELITIAN

Pendekatan penelitian ini menggunakan metode *rapid review* yang berfokus pada pencarian, seleksi, penilaian, dan sintesis artikel secara efisien. Strategi pencarian dilakukan dengan mengakses beberapa database seperti Google Scholar, PubMed, dan Scopus. Kata kunci dalam bahasa Inggris seperti *deep learning*, *diagnose*, dan *medical image* digunakan dalam proses pencarian begitu pula kata kunci dalam bahasa Indonesia seperti *deep learning*, *diagnosis*, dan *citra medis*. Artikel yang diperoleh disaring berdasarkan kriteria inklusi dan kriteria eksklusi. Kriteria inklusi meliputi artikel yang diterbitkan pada rentang tahun 2020-2025, tersedia dalam akses terbuka (*open access*), ditulis dalam bahasa Indonesia dan Inggris, relevan dengan kata kunci, artikel membahas citra medis yang digunakan merupakan MRI berbasis CNN, serta bukan merupakan *literature review*. Sementara itu, kriteria eksklusi mencakup artikel yang tidak relevan atau tidak memiliki data lengkap.

Hasil pencarian yang dilakukan pada 4 Februari 2025 melalui berbagai database ditemukan sebanyak 3340 artikel sesuai dengan kata kunci. Artikel tersebut kemudian diidentifikasi berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan dan menghasilkan 93 artikel untuk kembali diseleksi, sejumlah artikel dikecualikan karena tidak sesuai dengan kata kunci dan sebagian artikel tidak tersedia dalam akses terbuka. Seleksi artikel kemudian dilakukan dengan menggunakan metode PRISMA (*Preferred Reporting Items for Systematic Review*), menghasilkan 13 artikel yang memenuhi kriteria penelitian.



Gambar 1. Seleksi Artikel

3. HASIL DAN PEMBAHASAN

Tabel 1. Hasil Rapid Review Pendekatan CNN dalam Penggunaan MRI untuk Mendiganosis Penyakit

No	Author, Tahun dan Judul	Tujuan	Metode	Hasil
1.	Hong et al., (2023) <i>Application Exploration of Medical Image-aided Diagnosis of Breast Tumour Based on Deep Learning</i>	Tujuan dari penelitian ini adalah mengembangkan dan mengevaluasi model <i>deep learning</i> berbasis CNN tiga dimensi (3D) untuk membantu diagnosis tumor payudara menggunakan citra medis.	Metode yang digunakan dalam penelitian ini dimulai dengan pengumpulan data citra medis dari pasien, meskipun sumber spesifik database tidak disebutkan. Setelah data dikumpulkan, dilakukan proses pemilihan <i>Region of Interest</i> (ROI) yang mencakup area tumor, sehingga hanya bagian yang relevan dari citra yang dianalisis. Langkah selanjutnya adalah ekstraksi dan pemrosesan fitur dari ROI untuk	Hasil penelitian menunjukkan bahwa model 3D CNN yang dikembangkan memiliki kemampuan yang baik dalam mengekstrak fitur tumor dari citra medis. Model ini mampu menghasilkan akurasi diagnosis rata-rata sebesar 73,6% (0,736 dalam skala evaluasi), yang lebih tinggi

		meningkatkan kualitas data sebelum dimasukkan ke dalam model. Model yang dikembangkan dalam penelitian ini adalah CNN tiga dimensi (3D), yang dirancang untuk menganalisis struktur tumor dengan lebih baik dibandingkan model berbasis dua dimensi. Model ini kemudian dievaluasi berdasarkan indikator diagnostik untuk menilai efektivitasnya dalam mendeteksi tumor payudara.	dibandingkan dengan metode konvensional. Selain itu, efek ekstraksi ROI yang diterapkan dalam penelitian ini juga terbukti membantu meningkatkan kualitas analisis citra medis, sehingga memperbaiki performa sistem dalam mendeteksi tumor payudara.	
2.	Arunachalam & N, (2024) <i>Deep Learning-based Thigh Muscle Investigation Using MRI For Prosthetic Development for Patients Undergoing Total Knee Replacement (TKR)</i>	Penelitian ini bertujuan untuk melakukan penilaian kualitatif dan kuantitatif otot paha menggunakan MRI guna meningkatkan metode klasifikasi sinyal VAG yang ada untuk mendiagnosis kelainan pada pasien yang menjalani <i>Total Knee Replacement</i> (TKR).	Penelitian ini mengembangkan metode <i>deep learning</i> untuk penilaian kualitatif dan kuantitatif otot paha menggunakan MRI. Pada perangkat prostetik yang ada, pengukuran listrik otot seseorang diperoleh menggunakan elektroda permukaan atau implan. Beberapa metode digunakan untuk proses klasifikasi dan diagnosis, namun memiliki kelemahan dalam ekstraksi fitur dan memerlukan ahli untuk merancang sistem. Penelitian ini menggabungkan pemrosesan citra medis dan prostetik ortopedi untuk mengembangkan metode terapeutik.	Desain ini memberikan kontrol yang lebih presisi pada anggota tubuh prostetik menggunakan teknik pemrosesan citra. Metode hibrida CNN berbasis swarm mengukur struktur dan fungsi otot. Bersama dengan pembacaan sensor, detail ini digabungkan untuk kontrol prostetik. Implementasi dilakukan menggunakan MATLAB, SketchUp Pro, dan Arduino IDE Hasil penelitian menunjukkan bahwa penerapan algoritma CLAHE berhasil meningkatkan kualitas citra MRI dengan menghilangkan noise dan memperjelas fitur penting yang relevan untuk diagnosis. Model PCNN yang diusulkan mampu mempelajari fitur-fitur ini secara efektif, yang berkontribusi pada peningkatan akurasi dalam klasifikasi tumor otak. Meskipun penelitian ini tidak menyebutkan secara spesifik metrik evaluasi yang digunakan, hasilnya menunjukkan bahwa pendekatan gabungan
3.	Mgbejime et al., (2022) <i>Parallelistic Convolution Neural Network Approach for Brain Tumor Diagnosis</i>	Penelitian ini bertujuan untuk mengatasi masalah kualitas rendah pada citra MRI otak yang dapat mempengaruhi akurasi diagnosis tumor otak. Untuk itu, penulis mengusulkan pendekatan <i>Parallelistic Convolution Neural Network</i> (PCNN) yang dikombinasikan dengan algoritma <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE) untuk meningkatkan kualitas citra dan akurasi klasifikasi tumor.	Penelitian dimulai dengan penerapan algoritma CLAHE pada citra MRI otak untuk mengatasi masalah kualitas rendah akibat noise dan artefak. Algoritma ini berfungsi menghilangkan elemen noise dan meningkatkan fitur yang dapat dilatih pada citra. Setelah peningkatan kualitas citra, citra yang telah ditingkatkan ini dimasukkan ke dalam model PCNN yang diusulkan. Model PCNN ini dirancang untuk mempelajari fitur-fitur penting dari citra dan melakukan klasifikasi tumor menggunakan sigmoid classifier. Untuk melatih model secara efektif, digunakan dataset publik yang tersedia secara umum.	

4.	Mostafa et al., (2023) <i>Brain Tumor Segmentation Using Deep Learning on MRI Images</i>	Penelitian ini bertujuan untuk mengembangkan metode segmentasi tumor otak pada citra MRI menggunakan teknik <i>deep learning</i> , dengan fokus pada peningkatan akurasi dan efisiensi dalam mendeteksi dan mengklasifikasikan tumor otak.	Para peneliti mengumpulkan dataset citra MRI otak yang mencakup berbagai jenis tumor. Peneliti kemudian menerapkan model deep learning berbasis CNN untuk melakukan segmentasi tumor pada citra tersebut. Model CNN dilatih untuk mengenali dan membedakan antara jaringan sehat dan jaringan tumor, dengan tujuan meningkatkan akurasi deteksi.	CLAHE dan PCNN memiliki potensi yang signifikan dalam meningkatkan akurasi diagnosis tumor otak. Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan mampu melakukan segmentasi tumor otak dengan akurasi yang tinggi. Model ini berhasil mengidentifikasi dan memisahkan area tumor dari jaringan otak sehat pada citra MRI, menunjukkan potensi yang signifikan dalam membantu diagnosis klinis.
5.	Shahzadi et al., (2023) <i>Nerve Root Compression Analysis to Find Lumbar Spine Stenosis on MRI Using CNN</i>	Penelitian ini bertujuan untuk mengembangkan metode otomatis berbasis CNN untuk mendeteksi <i>Lumbar Spine Stenosis</i> (LSS) pada citra MRI, dengan fokus pada analisis kompresi akar saraf.	Para peneliti mengumpulkan dataset citra MRI lumbar yang mencakup berbagai kasus LSS. Peneliti menentukan empat ROI untuk mendiagnosis LSS, yang dikategorikan menjadi normal, ringan, sedang, dan berat. Model CNN kemudian dilatih untuk menganalisis kompresi akar saraf pada ROI tersebut, dengan tujuan mengklasifikasikan tingkat keparahan LSS secara otomatis.	Model CNN yang dikembangkan berhasil mengidentifikasi dan mengklasifikasikan tingkat keparahan LSS pada citra MRI dengan akurasi yang tinggi. Analisis kompresi akar saraf menggunakan pendekatan ini menunjukkan potensi yang signifikan dalam meningkatkan deteksi dan penilaian LSS secara otomatis.
6.	Tsai et al., (2021) <i>Lumbar Disc Herniation Automatic Detection in Magnetic Resonance Imaging Based on Deep Learning</i>	Penelitian ini bertujuan untuk mengembangkan metode deteksi otomatis Herniasi Diskus Lumbar (LDH) pada citra MRI menggunakan pendekatan <i>deep learning</i> . Tujuan utamanya adalah meningkatkan akurasi dan efisiensi dalam mendiagnosis LDH melalui analisis citra MRI.	Para peneliti mengumpulkan dataset citra MRI lumbar yang mencakup berbagai kasus LDH. Peneliti menerapkan model <i>deep learning</i> berbasis CNN untuk mendeteksi area herniasi pada citra tersebut. Model CNN dilatih untuk mengenali fitur-fitur spesifik yang berkaitan dengan LDH, dengan tujuan meningkatkan akurasi deteksi dan mengurangi waktu yang diperlukan untuk analisis manual.	Model CNN yang dikembangkan berhasil mendeteksi area herniasi pada citra MRI dengan tingkat akurasi yang tinggi. Pendekatan ini menunjukkan potensi yang signifikan dalam meningkatkan efisiensi diagnosis LDH, memungkinkan deteksi yang lebih cepat dan akurat dibandingkan dengan metode tradisional.
7.	Al-Otaibi et al., (2024) <i>CVG-Net: novel transfer learning based</i>	Penelitian ini bertujuan untuk mengembangkan pendekatan jaringan saraf tiruan yang efektif untuk	Studi ini menggunakan dataset gambar MRI multi-kelas yang terdiri dari 21.672 gambar terkait dengan tumor glioma, tumor meningioma, dan tumor pituitari. CVG-Net mengekstraksi fitur	Eksperimen menunjukkan bahwa dengan menggunakan CVG-Net, model k-neighbors classifier mencapai skor akurasi

	<p><i>deep features for diagnosis of brain tumors using MRI scans</i></p>	<p>diagnosis tepat waktu tumor otak. Para peneliti memperkenalkan metode rekayasa fitur berbasis jaringan saraf tiruan yang menggabungkan 2D Convolutional Neural Network (2DCNN) dan VGG16, yang disebut sebagai CVG-Net.</p>	<p>spasial dari gambar MRI menggunakan 2DCNN dan VGG16 tanpa intervensi manusia. Set fitur hibrida yang dihasilkan kemudian dimasukkan ke dalam model pembelajaran mesin untuk mendiagnosis tumor otak. Untuk mengatasi ketidakseimbangan data, peneliti menerapkan teknik <i>Synthetic Minority Over-sampling Technique</i> (SMOTE).</p>	<p>k-fold sebesar 0,96, mengungguli studi-studi terkini. Peneliti juga menerapkan penyesuaian hiperparameter untuk meningkatkan kinerja dalam diagnosis tumor otak multi-kelas.</p>
8.	<p>Wernér et al., (2024) <i>Detecting Avascular Necrosis of the Lunate from Radiographs Using a Deep-Learning Model</i></p>	<p>Penelitian ini bertujuan untuk mengembangkan model <i>deep learning</i> berbasis segmentasi untuk mendiagnosis <i>avascular necrosis</i> (AVN) pada tulang lunatum melalui radiograf postero-anterior pergelangan tangan.</p>	<p>Para peneliti mengumpulkan 319 radiograf dengan AVN pada tulang lunatum dan 1.228 radiograf kontrol dari basis data Rumah Sakit Pusat Universitas Helsinki. Sebanyak 10% dari data ini dipisahkan sebagai set uji untuk validasi model. Diagnosis AVN dikonfirmasi oleh ahli bedah tangan menggunakan MRI atau radiografi. Model <i>deep learning</i> yang dikembangkan difokuskan pada segmentasi untuk mendeteksi AVN pada radiograf tersebut.</p>	<p>Model ini menunjukkan sensitivitas sebesar 93,33% (interval kepercayaan 95%: 77,93–99,18%), spesifisitas 93,28% (IK 95%: 87,18–97,05%), dan akurasi 93,28% (IK 95%: 87,99–96,73%). Area di bawah kurva ROC adalah 0,94 (IK 95%: 0,88–0,99). Dibandingkan dengan tiga ahli klinis, model ini memiliki AUC yang lebih baik daripada satu ahli, dan hanya satu ahli yang memiliki akurasi lebih tinggi daripada model <i>deep learning</i> tersebut. Hasil eksperimen menunjukkan bahwa ICUnet++ mencapai nilai IoU sebesar 83,16%, DSC sebesar 90,32%, TPR sebesar 90,40%, dan PPV sebesar 90,52%. Indikator segmentasi ini menunjukkan peningkatan yang signifikan, mencerminkan efektivitas model yang diusulkan.</p>
9.	<p>L. Li et al., (2023) <i>ICUnet++: an Inception-CBAM network based on Unet++ for MR spine image segmentation</i></p>	<p>Penelitian ini bertujuan untuk mengembangkan model segmentasi otomatis yang efisien untuk gambar MRI tulang belakang. Model yang diusulkan, bernama ICUnet++, dirancang untuk meningkatkan akurasi segmentasi dengan memanfaatkan struktur Inception dan mekanisme perhatian (<i>attention mechanism</i>) dalam arsitektur Unet++.</p>	<p>ICUnet++ menggantikan modul awal dengan struktur Inception pada tahap encoder-decoder berbasis Unet++. Pendekatan ini menggunakan koneksi paralel dari beberapa kernel konvolusi untuk memperoleh fitur dengan berbagai bidang reseptif selama ekstraksi fitur. Selain itu, modul Attention Gate dan CBAM (<i>Convolutional Block Attention Module</i>) diterapkan dalam jaringan untuk menyoroti karakteristik area lokal yang relevan. Untuk mengevaluasi kinerja segmentasi model, digunakan empat metrik evaluasi: <i>Intersection over Union</i> (IoU), <i>Dice Similarity Coefficient</i> (DSC), <i>True Positive Rate</i> (TPR),</p>	

10.	Ullah et al., (2024) <i>A Deep Learning Based Intelligent Decision Support System for Automatic Detection of Brain Tumor</i>	Penelitian ini bertujuan untuk mengembangkan sistem pendukung keputusan cerdas berbasis deep learning untuk deteksi otomatis tumor otak. Dengan memanfaatkan model <i>deep learning</i> , khususnya CNN, penelitian ini berfokus pada ekstraksi fitur dari citra otak untuk mendeteksi tumor secara akurat.	dan <i>Positive Predictive Value</i> (PPV). Eksperimen dilakukan menggunakan dataset MRI tulang belakang yang dipublikasikan, yaitu SpineSagT2Wdataset3. Para peneliti mengembangkan dan menguji beberapa model CNN, termasuk model yang dibangun dari awal dan model transfer learning seperti VGG-16, VGG-19, dan LeNet-5, pada citra otak. Karena model deep learning memerlukan data dalam jumlah besar, mereka menerapkan teknik augmentasi data untuk meningkatkan ukuran dataset secara sintesis. Selain itu, penyesuaian hiperparameter dilakukan untuk mengoptimalkan parameter selama pelatihan model.	Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan mampu mengekstraksi fitur yang berbeda dari citra otak, memungkinkan deteksi tumor otak secara otomatis. Model transfer learning seperti VGG-16, VGG-19, dan LeNet-5 menunjukkan kinerja yang menjanjikan dalam mendeteksi tumor otak.
11.	Qodri, (2024) <i>Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning</i>	Penelitian ini bertujuan untuk membandingkan kinerja beberapa model deep learning dalam mengklasifikasikan tumor otak berdasarkan citra MRI, dengan fokus pada penerapan teknik <i>transfer learning</i> untuk meningkatkan akurasi deteksi.	Penelitian ini menggunakan dataset publik yang terdiri dari 3.618 gambar MRI, dengan 2.010 gambar otak tanpa tumor dan 1.608 gambar otak dengan tumor. Model deep learning yang digunakan meliputi <i>Residual Network</i> (ResNet50), Xception, dan <i>Visual Geometry Group</i> (VGG16). <i>Transfer learning</i> diterapkan untuk memanfaatkan pengetahuan dari model yang telah dilatih sebelumnya pada dataset besar guna meningkatkan kinerja pada tugas spesifik ini.	Hasil eksperimen menunjukkan bahwa model ResNet50 dan VGG16 mencapai akurasi sebesar 96% dalam mengklasifikasikan gambar MRI tumor otak. Hal ini menunjukkan bahwa kedua model tersebut efektif dalam mendeteksi keberadaan tumor otak.
12.	Aulia & Alamsyah, (2024) <i>Peningkatan Hiperparameter Framework Deep Learning VGG-16 untuk Pendeteksian Tumor Otak pada Teknologi MRI</i>	Penelitian ini bertujuan untuk meningkatkan kemampuan model VGG-16 yang dimodifikasi melalui penyesuaian hiperparameter dalam mendeteksi gambar MRI tumor otak manusia. Penelitian ini berfokus pada peningkatan akurasi deteksi dengan melakukan augmentasi data dan penambahan lapisan klasifikasi pada model.	Dataset yang digunakan berasal dari <i>Brain MRI Tumor Dataset</i> di Kaggle, yang terdiri dari empat kategori tumor otak. Model VGG-16 dimodifikasi dengan melakukan augmentasi data melalui penyesuaian kecerahan dan kontras, serta menambahkan lapisan klasifikasi. Hiperparameter yang disesuaikan meliputi laju pembelajaran (<i>learning rate</i>), ukuran batch (<i>batch size</i>), jumlah epoch, dan optimizer.	Hasil penelitian menunjukkan bahwa model yang diterapkan mencapai akurasi sebesar 95,63%, presisi 95,69%, recall 95,58%, dan skor F1 95,57%. Model yang dimodifikasi ini menunjukkan potensi dalam meningkatkan akurasi dan efisiensi diagnosis tumor otak menggunakan teknologi MRI.

13.	Ardan & Indraswari, (2024) Sistem Berbasis Deep Learning untuk Segmentasi dan Klasifikasi Tingkat Keganasan Tumor Otak Menggunakan Citra MRI 3D	Penelitian ini bertujuan mengembangkan sistem berbasis deep learning untuk segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D. Tujuannya adalah untuk meningkatkan akurasi dan efisiensi dalam penanganan kasus tumor otak, yang sering kali memerlukan analisis manual citra MRI yang dapat menyebabkan variasi hasil antar dokter.	Penelitian ini mengusulkan dua model <i>deep learning</i> untuk melakukan segmentasi dan klasifikasi tumor otak pada citra MRI 3D. Model pertama adalah model segmentasi yang menggunakan arsitektur U-Net, yang terkenal dalam tugas segmentasi citra medis. U-Net dilatih dengan dataset MRI selama 250 epoch, dan hasilnya menunjukkan performa yang baik dengan nilai <i>dice coefficient</i> sebesar 82% dan mean <i>Intersection over Union</i> (IoU) mencapai 94%. Model kedua adalah model klasifikasi yang menggunakan CNN dengan base model ResNet50V2 yang sudah dilatih pada dataset ImageNet. Kemudian, ditambahkan lapisan dense dengan 512 nodes pada bagian kepala model, yang memproses citra menjadi dua kelas, yaitu <i>Low-Grade Glioma</i> (LGG) dan <i>High-Grade Glioma</i> (HGG). Model klasifikasi ini dilatih selama 10 epoch dan menghasilkan akurasi sebesar 97%. Kedua model ini dikembangkan untuk mengoptimalkan hasil analisis citra medis dalam mengidentifikasi tumor otak dengan akurasi tinggi dan efisiensi yang lebih baik.	Sistem yang dikembangkan berhasil melakukan segmentasi dan klasifikasi tingkat keganasan tumor otak pada citra MRI 3D dengan akurasi tinggi. Model segmentasi menunjukkan performa yang baik dengan nilai <i>dice coefficient</i> 82% dan mean IoU 94%. Model klasifikasi mencapai akurasi 97% dalam mengidentifikasi dua kelas tumor otak.
-----	---	---	---	---

Di era globalisasi ini yang ditandai dengan kemajuan teknologi informasi dan komunikasi, integrasi kecerdasan buatan atau disebut dengan AI dalam bidang kesehatan telah menjadi fokus utama dalam meningkatkan efisiensi dan akurasi diagnosis medis. Salah satu penerapan signifikan adalah penggunaan CNN sebagai metode *deep learning*, yang merupakan arsitektur jaringan saraf tiruan yang dirancang untuk memproses data berbentuk grid, seperti gambar. Dalam bidang kesehatan, CNN telah diterapkan untuk mendeteksi dan mengklasifikasikan berbagai penyakit melalui analisis citra medis, salah satunya dalam analisis citra MRI (Tajuddin et al., 2024). Selain itu, AI berperan penting dalam meningkatkan efisiensi proses akuisisi MRI. Dengan memanfaatkan AI, waktu yang dibutuhkan untuk melakukan pemindaian dapat dikurangi secara signifikan tanpa mengorbankan kualitas gambar. Hal ini memungkinkan diagnosis yang lebih cepat dan efisien dalam praktik klinis, dengan potensi untuk mengubah paradigma pencitraan medis di masa depan (Candra et al., 2024).

3.1. MRI dengan Convolutional Neural Networks (CNN) sebagai metode deep learning

Berbagai jenis CNN telah dikembangkan untuk meningkatkan kinerja dalam analisis MRI. Dari hasil studi literature penelitian ini terdapat berbagai metode dan jenis penggunaan CNN dalam MRI yaitu Metode hibrida CNN berbasis swarm merupakan pendekatan yang menggabungkan CNN dengan algoritma optimasi berbasis *swarm intelligence* untuk meningkatkan akurasi dan efisiensi dalam analisis citra medis, terutama dalam MRI. Berbagai arsitektur CNN telah dikembangkan, seperti 2D-CNN dan

3D-CNN, yang memiliki keunggulan masing-masing. 2D-CNN banyak digunakan untuk analisis citra MRI dalam bentuk irisan tunggal, sementara 3D-CNN lebih efektif dalam menangkap hubungan spasial antar irisan, sehingga lebih cocok untuk analisis citra volumetrik, seperti deteksi tumor otak dan penyakit *neurodegenerative*

Selain itu, pendekatan *parallelistic neural network* digunakan untuk meningkatkan efisiensi pemrosesan data dengan mengoptimalkan proses komputasi secara paralel. Untuk meningkatkan kualitas citra sebelum diproses oleh CNN, teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sering diterapkan untuk meningkatkan kontras dan mempertajam detail struktur jaringan dalam MRI. Beberapa model CNN yang populer dalam analisis MRI meliputi VGG-16, VGG-19, LeNet-5, ResNet50, dan U-Net. VGG-16 dan VGG-19 terkenal dengan struktur konvolusinya yang dalam dan sering digunakan dalam klasifikasi citra medis. LeNet-5, sebagai model yang lebih ringan, cocok untuk tugas klasifikasi sederhana, sementara ResNet50, dengan residual learning, mengatasi masalah *vanishing gradient*, sehingga lebih stabil dalam menangani data kompleks.

Dalam tugas segmentasi MRI, model U-Net dan ICUnet++ sering digunakan karena memiliki arsitektur encoder-decoder, yang mampu mempertahankan detail penting dalam citra medis. ICUnet++ adalah versi yang lebih canggih dari U-Net dengan peningkatan dalam struktur arsitektur untuk segmentasi presisi tinggi. Kombinasi VGG-16, CLAHE, dan 2D-CNN dalam model CVG-Net juga menunjukkan peningkatan dalam klasifikasi MRI dengan kontras yang lebih optimal.

Pemilihan metode terbaik tergantung pada tujuan spesifik dalam analisis MRI. Jika fokus pada klasifikasi citra MRI, maka ResNet50, VGG-16, dan CVG-Net adalah pilihan terbaik karena memiliki tingkat akurasi tinggi dan stabilitas dalam pengolahan citra medis. Untuk segmentasi MRI, U-Net dan ICUnet++ lebih disarankan karena mampu menghasilkan segmentasi presisi tinggi dalam mendeteksi jaringan abnormal, seperti tumor atau lesi otak. Jika analisis memerlukan pemrosesan MRI dalam bentuk volumetrik, maka 3D-CNN lebih efektif dibandingkan 2D-CNN karena mempertimbangkan hubungan spasial antar irisan MRI.

3.2. MRI Konvensional dan MRI Modern

Berdasarkan tinjauan beberapa penelitian yang menggunakan MRI dalam diagnosis medis, terdapat dua kategori utama: MRI konvensional dan MRI modern. Enam jurnal menggunakan MRI konvensional, misalnya, penelitian oleh Hong et al., (2023) yang menggabungkan MRI konvensional dengan 3D CNN untuk diagnosis tumor payudara, menghasilkan akurasi 73,6%. Al-Otaibi et al., (2024) memanfaatkan MRI konvensional yang diproses dengan *deep learning* berbasis CNN dan *transfer learning* untuk diagnosis tumor otak, sedangkan L. Li et al., (2023) mengintegrasikan MRI konvensional dengan *deep learning* berbasis CNN untuk segmentasi gambar tulang belakang dengan tingkat akurasi 96%. Aulia & Alamsyah, (2024) menggunakan CNN yang dimodifikasi untuk mendeteksi tumor otak dari gambar MRI konvensional dengan akurasi sebesar 95,63%. Penelitian Wernér et al., (2024) menggunakan MRI konvensional untuk mendiagnosis *avascular necrosis* (AVN) pada tulang lunatum dengan tingkat akurasi 93,8%. Penelitian Ardan & Indraswari, (2024) memanfaatkan MRI konvensional dengan model *Residual Network* (ResNet50), Xception, dan VGG16 serta *transfer learning* mencapai akurasi 98% dalam segmentasi tumor otak menggunakan model CNN berbasis U-Net dan teknik ensembling.

Sebaliknya, tujuh jurnal memanfaatkan MRI modern. Arunachalam & N, (2024) mengaplikasikan MRI modern dengan teknologi *deep learning* untuk investigasi otot paha dalam pengembangan prostetik *Total Knee Replacement* (TKR), menghasilkan akurasi rata-rata 73,6%. Mgbejime et al., (2022) menggunakan MRI modern yang diintegrasikan dengan *Parallelistic CNN* (PCNN) untuk mendeteksi tumor otak dengan akurasi 98,7%. Mostafa et al., (2023) memanfaatkan DCNN berbasis U-Net pada citra MRI modern untuk segmentasi tumor otak. Shahzadi et al., (2023) menggunakan CNN untuk mengklasifikasikan tingkat keparahan stenosis dengan gambar MRI modern. Tsai et al., (2021) menerapkan YOLOv3 pada citra MRI modern untuk deteksi otomatis herniasi diskus lumbal (LDH). Ullah et al., (2024) memanfaatkan *deep learning* CNN dan *transfer learning* untuk mendeteksi BT dari citra otak untuk mendeteksi tumor secara akurat, sementara Qodri, (2024) menggunakan CNN dan

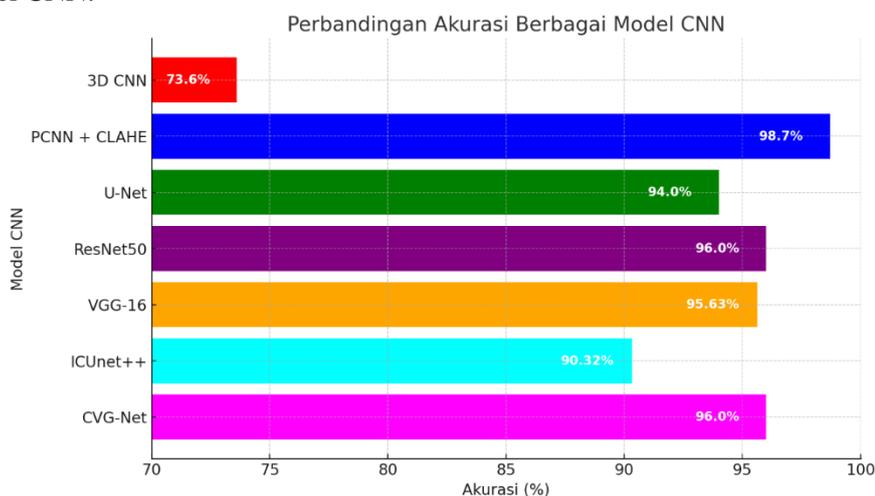
transfer learning untuk mengklasifikasikan tumor otak dari citra MRI modern dengan tingkat akurasi sebesar 96%.

Berbagai penelitian telah membuktikan efektivitas AI dalam mendeteksi penyakit secara akurat, dengan tingkat akurasi 73,6% - 98,7% tergantung jenis CNN yang digunakan. Misalnya, penelitian oleh Hong et al., (2023) menunjukkan akurasi 73,6% dalam deteksi tumor payudara menggunakan model 3D CNN dengan teknik ROI, sedangkan penelitian oleh Ardan & Indraswari, (2024) mencapai akurasi 98% dalam segmentasi tumor otak menggunakan model CNN berbasis U-Net dan teknik ensembling. Penelitian Tsai et al., (2021) menunjukkan akurasi 92,4% dalam mendeteksi herniasi diskus lumbal dengan model CNN. Model *deep learning* berbasis segmentasi juga menunjukkan sensitivitas 93,33% dan spesifisitas 93,28% dalam mendeteksi AVN pada tulang lunatum. Dalam kasus stenosis tulang belakang, CNN dengan pendekatan single-ROI dan multi-ROI mencapai akurasi masing-masing 97,71% dan 97,01%, mengungguli metode lain seperti SegNet, ResNet, dan U-Net (Wernér et al., 2024). Model ICUnet++ meningkatkan akurasi segmentasi MRI tulang belakang dengan nilai IoU 83,16% dan DSC 90,32%, sedangkan CVG-Net yang menggabungkan 2D CNN dan VGG16 mencapai akurasi 96% dalam diagnosis tumor otak. Dengan demikian, dapat disimpulkan bahwa MRI modern dengan teknologi deep learning dan CNN telah lebih banyak digunakan dalam penelitian terbaru, menghasilkan analisis medis yang lebih akurat dan efisien.

Tabel 2. Perbandingan Akurasi Model CNN dalam Diagnosis Penyakit dengan MRI

No	Model CNN	Tujuan Penelitian	Dataset	Akurasi (%)
1	3D CNN	Diagnosis tumor payudara	Citra medis pasien	73.6
2	PCNN + CLAHE	Deteksi tumor otak	Dataset publik	98.7
3	U-Net	Segmentasi tumor otak	Citra MRI modern	94.0
4	ResNet50	Klasifikasi tumor otak	Dataset publik	96.0
5	VGG-16	Deteksi tumor otak	Brain MRI Dataset	95.63
6	ICUnet++	Segmentasi MRI tulang belakang	SpineSagT2Wdataset3	90.32
7	CVG-Net	Diagnosis tumor otak multi-kelas	MRI multi-kelas	96.0

Untuk memberikan pemahaman yang lebih mendalam, berikut adalah grafik perbandingan akurasi berbagai model CNN:



Gambar 2. Model CNN

Hasil penelitian menunjukkan bahwa berbagai model CNN memiliki performa yang berbeda dalam diagnosis berbasis MRI. Beberapa penelitian sebelumnya juga menunjukkan hasil serupa:

- Hong et al. (2023) menggunakan 3D CNN dan memperoleh akurasi 73,6% dalam deteksi tumor payudara.

- Ardan & Indraswari (2024) mengadopsi model berbasis ResNet50 dan Xception untuk segmentasi tumor otak, mencapai akurasi hingga 98%.
- Tsai et al. (2021) menggunakan YOLOv3 dalam mendeteksi herniasi diskus lumbal dengan akurasi 92,4%.
- Wernér et al. (2024) menerapkan deep learning berbasis segmentasi untuk mendeteksi avascular necrosis dengan akurasi 93,3%.

Berdasarkan perbandingan ini, dapat disimpulkan bahwa model yang lebih kompleks seperti PCNN dan transfer learning (CVG-Net) menunjukkan performa terbaik, terutama dalam klasifikasi multi-kelas.

3.3. Kelebihan dan Kekurangan CNN dalam Diagnosis Berbasis MRI

Kelebihan:

- Akurasi Tinggi: Beberapa model seperti ResNet50 dan CVG-Net mencapai akurasi di atas 95%.
- Kemampuan Ekstraksi Fitur Otomatis: CNN dapat mengenali pola kompleks dalam citra MRI tanpa memerlukan ekstraksi fitur manual.
- Efisiensi Diagnosis: Deep learning memungkinkan deteksi cepat dibandingkan dengan metode konvensional yang bergantung pada tenaga medis.

Kekurangan:

- Ketergantungan pada Data Berkualitas: Model CNN sangat bergantung pada dataset besar dan berkualitas tinggi.
- Kebutuhan Sumber Daya Komputasi Tinggi: Model yang lebih kompleks memerlukan GPU atau TPU untuk pelatihan optimal.
- Kurangnya Validasi Klinis: Beberapa model masih belum diuji dalam skala klinis yang luas, sehingga memerlukan lebih banyak uji coba.

Meskipun AI menunjukkan kinerja yang luar biasa, ada beberapa tantangan yang masih harus diatasi. Salah satu tantangan utama adalah kebutuhan data berkualitas. Model AI sangat bergantung pada dataset yang besar dan berkualitas tinggi, di mana ketidakseimbangan data dapat menyebabkan bias dalam prediksi. Selain itu, implementasi AI di lingkungan klinis memerlukan infrastruktur komputasi yang mumpuni, yang dapat menjadi kendala bagi beberapa institusi medis. Kurangnya validasi klinis juga menjadi hambatan, karena beberapa model AI masih dalam tahap penelitian dan belum banyak diuji dalam kondisi dunia nyata. Tidak kalah pentingnya, adopsi AI dalam dunia medis masih menghadapi resistensi dari tenaga medis yang belum sepenuhnya percaya pada akurasi dan keandalan teknologi ini.

4. KESIMPULAN

Penerapan *Convolutional Neural Networks* (CNN) dapat secara signifikan meningkatkan akurasi diagnosis penyakit menggunakan MRI, dengan tingkat akurasi yang bervariasi antara 73,6% hingga 98,7%. Berbagai model dalam CNN, seperti 3 D CNN dan U-Net terbukti efektif dalam mendeteksi dan mengklasifikasikan berbagai penyakit, termasuk tumor otak dan penyakit kardiovaskular. Meskipun hasil yang diperoleh sangat menjanjikan, tantangan seperti kebutuhan akan data berkualitas tinggi dan validasi klinis masih perlu diatasi untuk memastikan implementasi yang sukses dalam praktis medis. Implikasi dari penelitian ini dalam dunia medis sangat relevan karena hasilnya dapat diterapkan untuk mengembangkan sistem diagnosis berbasis AI yang lebih akurat dan efisien. Dengan integrasi teknologi *deep learning*, proses diagnosis dapat menjadi lebih otomatis, yang pada gilirannya dapat mengurangi beban kerja tenaga medis dan meningkatkan kualitas layanan kesehatan secara keseluruhan.

Penelitian ini dapat dikembangkan kembali dengan memfokuskan pada pengumpulan dan pengembangan dataset yang lebih besar dan berkualitas tinggi untuk melatih model AI, sehingga mengurangi bias dan meningkatkan akurasi. Selain itu, diperlukan lebih banyak studi untuk melakukan validasi klinis dari model-model yang telah dikembangkan, untuk memastikan diimplementasikan secara efektif dalam praktis medis sehari-hari. Penelitian selanjutnya juga dapat mengeksplorasi model *deep learning* lainnya dan teknik optimasi untuk meningkatkan performa diagnosis, serta membandingkan efektivitas berbagai pendekatan dalam konteks aplikasi klinis yang berbeda.

DAFTAR PUSTAKA

- Al-Otaibi, S., Rehman, A., Raza, A., Alyami, J., & Saba, T. (2024). CVG-Net: novel transfer learning based deep features for diagnosis of brain tumors using MRI scans. *PeerJ Computer Science*, *10*, 1–24. <https://doi.org/10.7717/peerj-cs.2008>
- Arabahmadi, M., & Farahbakhsh, R. (2022). Deep Learning for Smart Healthcare: A Survey on Brain Tumor. *Sensors*, *22*, 1–27.
- Ardan, I. S., & Indraswari, R. (2024). Sistem Berbasis Deep Learning untuk Segmentasi dan Klasifikasi Tingkat Keganasan Tumor Otak Menggunakan Citra MRI 3D. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, *6*(2), 117–126.
- Arunachalam, V., & N, K. (2024). Deep Learning-based Thigh Muscle Investigation Using MRI For Prosthetic Development for Patients Undergoing Total Knee Replacement (TKR). *Current Medical Imaging*, *20*, 1–15. <https://doi.org/10.2174/0115734056284002240318055326>
- Aulia, A. B. A. I., & Alamsyah. (2024). Peningkatan Giperparameter Framework Deep Learning VGG-16 untuk Pendeteksian Tumor Otak pada Teknologi MRI. *Indonesian Journal of Mathematics and Natural Sciences*, *47*(2), 99–107.
- Brima, Y., Kamal Tushar, M. H., Kabir, U., & Islam, T. (2022). Deep Transfer Learning for Brain Magnetic Resonance Image Multi-class Classification. *Dhaka University Journal of Applied Science and Engineering*, *6*(2), 14–29. <https://doi.org/10.3329/dujase.v6i2.59215>
- Candra, D., Wibisono, G., Ayu, M., & Afrad, M. (2024). Transfer Learning model Convolutional Neural Network menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI. *LEDGER: Journal Informatic and Information Technology*, *3*(1), 11–18.
- Farwati, M., Salsabila, I. T., Navira, K. R., & Sutabri, T. (2023). Analisa Pengaruh Teknologi Artificial Intelligence (AI) dalam Kehidupan Sehari-hari. *Jurnal Sistem Informatika Dan Manajemen*, *11*(1), 39–45.
- Hidayaturrahman, F. (2024). *Klasifikasi Tumor Otak pada Citra Magnetic Resonance Imaging Menggunakan Convolutional Neural Network Berbasis Web*.
- Hong, Z., Yan, X., Zhang, R., Ren, Y., Tong, Q., & Altrjman, C. (2023). Application Exploration of Medical Image-aided Diagnosis of Breast Tumour Based on Deep Learning. *Current Medical Imaging*, *20*, 1–14. <https://doi.org/10.2174/0115734056261997231217085501>
- Hussain, E., Hasan, M., Hassan, S. Z., Azmi, T. H., Rahman, M. A., & Parvez, M. Z. (2020). Deep Learning Based Binary Classification for Alzheimer’s Disease Detection using Brain MRI Images. *Proceedings of the 15th IEEE Conference on Industrial Electronics and Applications, ICIEA 2020*, 1115–1120. <https://doi.org/10.1109/ICIEA48937.2020.9248213>
- IBM. (2023). *Manfaat AI dalam Layanan Kesehatan | IBM*. International Business Machines Corporation. <https://www.ibm.com/id-id/think/insights/ai-healthcare-benefits>
- Li, L., Qin, J., Lv, L., Cheng, M., Wang, B., Xia, D., & Wang, S. (2023). ICUnet++: an Inception-CBAM network based on Unet++ for MR spine image segmentation. *International Journal of Machine Learning and Cybernetics*, *14*(10), 3671–3683. <https://doi.org/10.1007/s13042-023-01857-y>
- Li, S., Qu, H., Dong, X., Dang, B., Zang, H., & Gong, Y. (2024). *Leveraging Deep Learning and Xception Architecture for High-Accuracy MRI Classification in Alzheimer Diagnosis*. 1–9.
- McGenity, C., Emily L Clarke, Charlotte Jennings, Gillian Matthews, Caroline Cartlidge, Henschel Freduah-Agyemang, Deborah D Stocken, & Darren Treanor. (2023). Artificial intelligence in digital pathology: a diagnostic test accuracy systematic review and meta-analysis. *Cornell University*, 1–43.
- Mgbejime, G. T., Hossin, M. A., Nneji, G. U., Monday, H. N., & Ekong, F. (2022). Parallelistic Convolution Neural Network Approach for Brain Tumor Diagnosis. *Diagnostics*, *12*(10), 1–20. <https://doi.org/10.3390/diagnostics12102484>

- Mostafa, A. M., Zakariah, M., & Aldakheel, E. A. (2023). Brain Tumor Segmentation Using Deep Learning on MRI Images. *Diagnostics*, *13*(9), 1–22. <https://doi.org/10.3390/diagnostics13091562>
- Nayan, A. A., Mozumder, A. N., Haque, M. R., Sifat, F. H., Mahmud, K. R., Al Azad, A. K., & Kibria, M. G. (2023). A deep learning approach for brain tumor detection using magnetic resonance imaging. *International Journal of Electrical and Computer Engineering*, *13*(1), 1039–1047. <https://doi.org/10.11591/ijece.v13i1.pp1039-1047>
- Qodri, K. N. (2024). Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning. *Indonesian Journal of Information Technology*, *2*(1), 1–6.
- Rokom. (2024). *Diagnosis Penyakit Makin Canggih dengan Stetoskop AI – Sehat Negeriku*. Kementerian Kesehatan RI. https://sehatnegeriku.kemkes.go.id/baca/rilis-media/20240616/2145761/diagnosis-penyakit-makin-canggih-dengan-stetoskop-ai/?utm_source=chatgpt.com
- Shahzadi, T., Ali, M. U., Majeed, F., Sana, M. U., Diaz, R. M., Samad, M. A., & Ashraf, I. (2023). Nerve Root Compression Analysis to Find Lumbar Spine Stenosis on MRI Using CNN. *Diagnostics*, *13*(18), 1–19. <https://doi.org/10.3390/diagnostics13182975>
- Tajuddin, N. W., Wardhana, Y. W., & Indrati, R. (2024). Pemanfaatan Kecerdasan Buatan (AI) Pada MRI. *Jurnal Sudut Pandang*, *29–37*. <http://thejournalish.com/ojs/index.php/sudutpandang/article/view/814%0Ahttps://thejournalish.com/ojs/index.php/sudutpandang/article/download/814/538>
- Tsai, J. Y., Hung, I. Y. J., Guo, Y. L., Jan, Y. K., Lin, C. Y., Shih, T. T. F., Chen, B. Bin, & Lung, C. W. (2021). Lumbar Disc Herniation Automatic Detection in Magnetic Resonance Imaging Based on Deep Learning. *Frontiers in Bioengineering and Biotechnology*, *9*, 1–11. <https://doi.org/10.3389/fbioe.2021.708137>
- Ullah, Z., Jamjoom, M., Thirumalaisamy, M., Alajmani, S. H., Saleem, F., Sheikh-Akbari, A., & Khan, U. A. (2024). A Deep Learning Based Intelligent Decision Support System for Automatic Detection of Brain Tumor. *Biomedical Engineering and Computational Biology*, *15*, 1–13. <https://doi.org/10.1177/11795972241277322>
- Wernér, K., Anttila, T., Hulkkonen, S., Viljakka, T., Haapamäki, V., & Ryhänen, J. (2024). Detecting Avascular Necrosis of the Lunate from Radiographs Using a Deep-Learning Model. *Journal of Imaging Informatics in Medicine*, *37*(2), 706–714. <https://doi.org/10.1007/s10278-023-00964-0>

Halaman Ini Dikosongkan