

Perbandingan Klasifikasi Tumor Otak Pada Citra MRI Dengan Menggunakan Arsitektur CNN EfficientNetV2S, ResNet152V2, Dan VGG19

**Benedict Chilwin Punarto¹, Natanael Missionday Gloryant²,
Windra Swastika³**

Teknik Informatika, Universitas Ma Chung, Villa Puncak Tidar Blok N no. 1, Kabupaten Malang, Indonesia, 65151

***Email korespondensi:** bchilwinpun@gmail.com

Received: 27 05 2026 – Revised: 29 07 2026 - Accepted: 04 08 2026 - Published: 05 08 2026

Abstrak. Tumor otak merupakan salah satu penyakit neurologis serius yang membutuhkan diagnosis cepat dan akurat, di mana citra Magnetic Resonance Imaging (MRI) memegang peranan krusial. Interpretasi manual citra MRI seringkali memakan waktu dan bervariasi antar-pengamat, mendorong eksplorasi otomatisasi menggunakan deep learning. Penelitian ini bertujuan untuk membandingkan performa arsitektur pre-trained Convolutional Neural Network (CNN) EfficientNetV2S, ResNet152V2, dan VGG19 dalam klasifikasi tumor otak berdasarkan citra MRI. EfficientNetV2S dipilih karena dikenal dengan efisiensi parameter dan skalabilitasnya, sedangkan VGG19 merupakan model klasik yang telah terbukti kemampuannya dalam berbagai tugas klasifikasi citra. ResNet152V2 juga dipilih karena merupakan salah satu arsitektur dengan layer yang banyak dan model yang besar. Penelitian ini menggunakan dataset citra MRI tumor otak yang telah dianotasi untuk melatih dan mengevaluasi ketiga model. Hasil eksperimen menunjukkan bahwa ketiga konfigurasi model berhasil mengidentifikasi tumor otak dengan akurasi tinggi. Secara spesifik, EfficientNetV2S meraih akurasi testing tertinggi sebesar 99.2%, ResNet152V2 mendapatkan akurasi sebesar 98.8%, dan VGG19 mendapatkan akurasi sebesar 99.0%. Berdasarkan temuan ini, EfficientNetV2S terbukti menjadi pilihan yang lebih optimal, terutama jika mempertimbangkan efisiensi komputasi karena kemampuannya meraih akurasi tinggi dengan model yang lebih ringan. Meskipun demikian, VGG19 dan ResNet152V2 tetap memberikan hasil yang kompetitif dan layak dipertimbangkan, khususnya bila efisiensi komputasi bukan prioritas utama.

Kata kunci: EfficientNetV2S, MRI, ResNet152V2, Tumor otak, VGG19. PENDAHULUAN

PENDAHULUAN

Tumor otak adalah pertumbuhan sel-sel yang tidak normal atau membentuk massa di dalam otak. Karena otak terlindungi oleh tengkorak yang kaku dan tidak elastis, setiap pertumbuhan di ruang terbatas ini dapat menyebabkan masalah serius. Tumor otak dapat bersifat ganas (kanker) atau jinak (non-kanker). Kedua jenis tumor ini, bila ukurannya membesar, dapat meningkatkan tekanan di dalam tengkorak, yang berpotensi merusak otak dan bahkan mengancam jiwa. Tumor otak termasuk salah satu penyakit neurologis yang memiliki tingkat kematian dan morbiditas yang signifikan secara global.

Organisasi Kesehatan Dunia (WHO) melaporkan bahwa pada tahun 2022, Indonesia mencatat 5.259 kasus kematian dan 5.738 kasus baru akibat tumor otak (Global Cancer Observatory, 2022). Ada beragam jenis tumor otak, di antaranya yang paling sering ditemui adalah glioma, meningioma, dan tumor pituitari. Untuk mendiagnosis kondisi ini, dokter umumnya mengandalkan pencitraan *Magnetic Resonance Imaging* (MRI) guna memastikan keberadaan tumor. Namun, proses interpretasi hasil MRI saat ini masih dilakukan secara manual. Hal ini menuntut keahlian khusus dari dokter atau radiolog, bersifat subjektif, dan bisa berbeda-beda antara satu pengamat dengan yang lain. Kondisi ini berpotensi menyebabkan keterlambatan diagnosis atau bahkan ketidakakuratan dalam penentuan kondisi pasien (Abd-Ellah et al., 2019).

Seiring perkembangan teknologi kecerdasan buatan, khususnya deep learning, telah banyak penelitian yang berupaya mengotomatisasi klasifikasi tumor otak pada citra MRI untuk meningkatkan akurasi dan efisiensi diagnostik. Berbagai arsitektur *Convolutional Neural Network* (CNN) telah diterapkan pada masalah serupa dengan hasil yang menjanjikan, termasuk model-model *pre-trained* yang memanfaatkan transfer learning untuk mengatasi keterbatasan data (Amarnath et al., 2024). Penelitian terdahulu telah mengevaluasi model klasik seperti VGG19 yang terkenal karena kesederhanaan dan performa stabil, model-model baru seperti EfficientNet yang menawarkan efisiensi parameter dan skalabilitas tinggi, serta ResNet152V2 yang menawarkan model besar dengan 152-layer untuk menangkap fitur yang lebih kompleks.

Masyarakat/mitra yang menjadi target dalam penelitian ini adalah kalangan medis dan peneliti di bidang radiologi, yang membutuhkan sistem pendukung keputusan berbasis AI untuk membantu interpretasi citra MRI secara cepat dan konsisten. Sistem klasifikasi otomatis diharapkan dapat membantu mengurangi beban kerja ahli radiologi dan meningkatkan kualitas layanan diagnostik (Nair et al., 2025).

Tujuan dari penelitian ini adalah untuk membandingkan performa arsitektur CNN pre-trained EfficientNetV2S, ResNET152V2, VGG19 dan dalam klasifikasi tumor otak berbasis citra MRI untuk menentukan model yang optimal dari segi akurasi dan efisiensi.

MASALAH

Masalah utama yang menjadi fokus penelitian ini adalah kebutuhan akan sistem klasifikasi otomatis untuk mendukung diagnosis tumor otak pada citra MRI. Interpretasi

manual citra MRI rentan terhadap variasi antar-pengamat dan memakan waktu, sehingga berpotensi menyebabkan keterlambatan diagnosis yang krusial. Tantangan lain adalah bagaimana menghasilkan model *deep learning* yang tidak hanya akurat tetapi juga efisien secara komputasi, agar lebih mudah diimplementasikan pada sistem klinis dengan sumber daya terbatas.

Dalam bidang ilmiah, terdapat kebutuhan untuk mengkaji arsitektur CNN *pre-trained* mana yang lebih optimal untuk tugas klasifikasi citra medis, khususnya tumor otak. Penelitian sebelumnya telah menunjukkan bahwa model kecerdasan buatan (AI) berpotensi besar dalam deteksi tumor otak. Sebagai contoh, studi oleh Muftic, Kadunic, et al. (2024) yang menggunakan arsitektur serupa, melaporkan EfficientNetB3 mencapai akurasi pelatihan yang sangat tinggi (99,44%) namun menunjukkan potensi *overfitting*. Sementara itu, ResNet50 mencapai akurasi validasi yang sama baiknya (89,47%) dengan akurasi pelatihan 83,62%, dan VGG-19 berkinerja lebih rendah dengan akurasi hanya 62%. Temuan ini menggaris bawahi prospek AI dalam diagnosis tumor otak, sekaligus menyoroti perlunya mengatasi tantangan seperti *overfitting* sebelum implementasi luas. Oleh karena itu, masih diperlukan evaluasi komparatif yang sistematis antara model klasik seperti VGG-19 dan model modern. Dalam penelitian ini, kami menggunakan model modern yang telah diperbarui, yaitu EfficientNetV2S dan ResNet152V2, untuk menentukan pendekatan yang tidak hanya unggul dalam akurasi tetapi juga efisien dari sisi parameter, sehingga lebih layak diadopsi secara luas di fasilitas kesehatan.


METODE PELAKSANAAN

Penelitian ini mengadopsi metode simulasi untuk mengembangkan pemodelan sistem klasifikasi citra berbasis CNN sebagai karya utamanya. Simulasi ini akan berlangsung selama satu bulan dengan tujuan membandingkan dan menguji kinerja tiga arsitektur CNN *pre-trained* yang berbeda.

Pengumpulan Data

Data yang digunakan dalam penelitian diperoleh dari platform Kaggle dengan judul Brain Tumor MRI Dataset (Nickparvar, 2021). Dataset ini memiliki total 5000 gambar MRI otak yang terbagi menjadi empat kategori: Glioma (tumor pada sel glia), Meningioma (tumor pada selaput meninges), Pituitary (tumor pada kelenjar pituitari), dan No Tumor (kondisi normal). Dari jumlah tersebut, 4000 gambar dialokasikan untuk pelatihan, dengan


masing-masing kategori menyumbang 1000 gambar. Sementara itu, 1000 gambar sisanya digunakan sebagai data uji coba yang digabung dari keempat kategori. Contoh gambar dari setiap kategori disajikan pada **Gambar 1**.



Gambar 1. (dari kiri ke kanan) Contoh data MRI otak yang memiliki tumor glioma, meningioma, pituitary, dan *no tumor*.

Pra-pemrosesan

Setelah itu, data akan melalui serangkaian proses persiapan. Pertama, *watermark* pada gambar dihilangkan menggunakan kombinasi teknik *inpainting*. Kemudian, *noise* pada gambar akan diminimalisir dengan metode *Non-Local Means* dengan *filter strength* 10 ($h = 10$) dengan perbandingan *template window size* dan *search window size* 7:21. Selanjutnya, ukuran setiap gambar diseragamkan menjadi 100 x 100 piksel. Terakhir, *Contrast Limited Adaptive Histogram Equalization* (CLAHE) diterapkan untuk menyeimbangkan dan meningkatkan kontras intensitas warna pada gambar, memastikan kualitas visual yang optimal untuk analisis lebih lanjut.



(a)

(b)

Gambar 2. Perbandingan citra sebelum dan sesudah pra-pemrosesan. (a) menunjukkan citra sebelum di pra-proses, dan (b) menunjukkan citra setelah di pra-proses. Perlu diketahui bahwa gambar (b) berukuran 100x100.

Arsitektur

Dalam penelitian ini, kami memilih tiga arsitektur *deep learning* untuk klasifikasi citra, yaitu EfficientNetV2S, ResNet152V2, dan VGG19. Pemilihan ketiga arsitektur ini didasarkan pada karakteristik dan kapabilitasnya yang berbeda, termasuk ukuran parameter model, yang menjadi faktor krusial dalam mempertimbangkan efisiensi komputasi dan kinerja. Sebagai contoh, arsitektur EfficientNetV2S dikenal karena efisiensinya yang tinggi dalam penggunaan parameter dan komputasi (Tan & Le, 2021). Sementara itu, ResNet152V2 unggul dalam menangani kedalaman jaringan yang kompleks dan kemampuan ekstraksi fitur yang kuat (Bilal et al., 2022), dan VGG19 menjadi representasi model klasik dengan kedalaman yang signifikan yang masih relevan dalam berbagai aplikasi (V & T R, 2021).

Ketiga model tersebut akan memanfaatkan teknik *transfer learning* dengan bobot *pre-trained* dari *imagenet* untuk mempercepat konvergensi dan meningkatkan akurasi, terutama dengan dataset yang terbatas. Proses pelatihan akan menggunakan parameter sebagai berikut: *epochs* = 100, *batch_size* = 32, dan *image_size* = 100x100 piksel. Untuk mengoptimalkan pelatihan dan mencegah *overfitting*, kami menerapkan strategi *callback Early Stopping* dengan *patience* = 10, serta *Reduce LR On Plateau* dengan *factor* = 0.1, *patience* = 5, dan *min_lr* = 1e-8. Konfigurasi ini dirancang untuk memastikan pelatihan yang stabil dan efisien demi mendapatkan kinerja optimal dari setiap arsitektur.

Evaluasi


Model-model yang telah dilatih akan dievaluasi secara komprehensif menggunakan beberapa metrik. Kami akan menganalisis nilai *loss* dan *accuracy* selama fase pelatihan dan uji coba untuk melihat seberapa rendah *loss* dan seberapa tinggi *accuracy* yang dicapai. Selain itu, kami akan mengidentifikasi *epochs* optimal (dari total 100 epoch) di mana model mencapai kinerja terbaiknya. Evaluasi juga mencakup perhitungan akurasi per kategori untuk memahami performa model pada setiap jenis tumor. Lebih lanjut, kami akan menyusun *confusion matrix*, serta menghitung metrik *precision*, *recall*, dan *F1-score* untuk memberikan gambaran lengkap tentang kemampuan klasifikasi model.

HASIL DAN PEMBAHASAN

Hasil penelitian ini secara konsisten menunjukkan bahwa ketiga model CNN *pre-trained* yang dievaluasi memiliki kemampuan tinggi dalam mengklasifikasikan tumor otak pada citra MRI. Bagian berikut akan menyajikan hasil dan pembahasan terperinci untuk setiap model yang digunakan.

EfficientNetV2S


Berdasarkan grafik *loss* dan *accuracy* pada **Gambar 3**, model EfficientNetV2S menunjukkan performa pelatihan yang stabil dan konvergen. *Training loss* terus menurun hingga mencapai nilai minimum sebesar 0.0081. Meskipun *validation loss* mengalami fluktuasi ringan pada rentang epoch ke-10 hingga ke-15, nilainya tetap rendah dengan titik terendah sebesar 0.0201. Grafik *accuracy* menunjukkan peningkatan pesat pada awal pelatihan, dengan *training accuracy* maksimum sebesar 99.65% tercapai pada epoch ke-20, dan *validation accuracy* tertinggi sebesar 99.20% diperoleh lebih awal pada epoch ke-10.



Gambar 3. Grafik metrik *loss* dan *accuracy* pada model EfficientNetV2S.


Kemudian dengan penerapan teknik *early stopping*, proses pelatihan dihentikan secara otomatis pada epoch ke-26 ketika performa validasi tidak mengalami peningkatan signifikan. Pada titik ini, model mencatat *training accuracy* sebesar 99.65% dan *validation accuracy* sebesar 99.10%. Menariknya, performa validasi terbaik (99.20%) justru dicapai pada epoch ke-10. Sementara itu dalam klasifikasi per kelas, model menunjukkan performa sempurna pada kelas No Tumor dengan precision, recall, dan f1-score sebesar 1.000. Meskipun precision untuk kelas Meningioma sedikit menurun (0.9728), nilai recall tetap 1.000, menandakan kemampuan deteksi yang sangat baik. Kategori Glioma dan Pituitary

juga menunjukkan kinerja yang seimbang dengan f1-score masing-masing 0.9879 dan 0.9940.



Gambar 4. Ringkasan proses *training* pada model EfficientNetV2S


Terakhir, hasil *confusion matrix* mengonfirmasi performa tersebut, di mana seluruh data uji untuk kelas *Meningioma* dan *No Tumor* (250 sampel per kelas) diprediksi dengan benar. Sebanyak 245 dari 250 citra *Glioma* diklasifikasikan secara tepat, sementara lima sisanya salah diklasifikasikan sebagai *Meningioma*. Untuk kelas *Pituitary*, 247 sampel berhasil diprediksi benar, dengan tiga kesalahan klasifikasi (satu ke *Glioma*, dua ke *Meningioma*).



Gambar 5. Confusion matrix model EfficientNetV2S

ResNet152V2

Model ResNet152V2 menunjukkan tren konvergensi yang stabil, dengan *training loss* minimum sebesar 0.0032 meskipun terjadi fluktuasi pada epoch ke-4 hingga ke-18, yang menyebabkan perlunya pelatihan lebih panjang hingga mencapai stabilitas. *Validation loss* juga menunjukkan fluktuasi sejak awal hingga sekitar epoch ke-20, sebelum menurun dan mencapai nilai minimum sebesar 0.0329. Peningkatan *training accuracy* berlangsung cepat, mencapai 99.92% pada epoch ke-33, sementara *validation accuracy* tertinggi sebesar 98.80% diperoleh pada epoch ke-26. Proses pelatihan berlangsung selama 44 epoch sebelum dihentikan oleh *early stopping*, dengan *final accuracy* sebesar 99.90% untuk data latih dan 98.60% untuk data validasi.



Gambar 6. Grafik model *loss* dan model *accuracy* pada model ResNet152V2.

Kemudian hasil pengujian menunjukkan akurasi keseluruhan sebesar 98.80%. Model mampu mengklasifikasikan kategori *No Tumor* secara sempurna, sementara akurasi untuk *Glioma*, *Meningioma*, dan *Pituitary* masing-masing adalah 96.4%, 99.6%, dan 99.2%. Kategori *No Tumor* tercapai dengan precision, recall, dan f1-score sebesar 1.000. Untuk kelas *Meningioma*, meskipun precision sedikit menurun menjadi 0.9577, nilai recall yang tinggi (0.9960) menunjukkan kemampuan deteksi yang kuat. Sementara itu, *Glioma* dan *Pituitary* memperoleh f1-score masing-masing 0.9817 dan 0.9940, menunjukkan keseimbangan yang baik antara sensitivitas dan presisi.

```
=====
TRAINING SUMMARY
=====
Total Epochs: 44
Final Training Loss: 0.0048
Final Validation Loss: 0.0357
Final Training Accuracy: 0.9990
Final Validation Accuracy: 0.9860

Best Validation Loss: 0.0339 (Epoch 13)
Best Validation Accuracy: 0.9880 (Epoch 28)

=====
OVERFITTING ANALYSIS
=====
[✓] Good generalization
[✓] Balanced training and validation accuracy
```


```
=====
PER-CLASS ACCURACY:
=====
glioma : 0.9640 (96.40%)
meningioma : 0.9960 (99.60%)
no_tumor : 1.0000 (100.00%)
pituitary : 0.9920 (99.20%)

=====
DETAILED CLASSIFICATION REPORT:
=====
```

	precision	recall	f1-score	support
glioma	1.0000	0.9640	0.9817	250
meningioma	0.9577	0.9960	0.9765	250
no_tumor	1.0000	1.0000	1.0000	250
pituitary	0.9960	0.9920	0.9940	250
accuracy			0.9880	1000
macro avg	0.9884	0.9880	0.9880	1000
weighted avg	0.9884	0.9880	0.9880	1000

Gambar 7. Ringkasan proses *training* pada model ResNet152V2.


Hasil *confusion matrix* juga memperlihatkan bahwa semua sampel *No Tumor* (250 sampel) diprediksi dengan benar. Sebanyak 241 dari 250 citra *Glioma* terklasifikasi dengan tepat, dengan sembilan kesalahan prediksi ke kelas *Meningioma*. Untuk *Meningioma*, 249 sampel diklasifikasikan benar, dengan satu kesalahan sebagai *Pituitary*. Sementara itu, 248 dari 250 citra *Pituitary* dikenali dengan benar, dan dua lainnya salah diklasifikasikan sebagai *Meningioma*.



Gambar 8. Confusion matrix model ResNet152V2.


VGG19

Arsitektur VGG19 menunjukkan performa pelatihan yang stabil dengan *training loss* minimum sebesar 0.0019. Fluktuasi ringan tercatat pada epoch ke-5 hingga ke-8 dan ke-10 hingga ke-12. *Validation loss* mulai menunjukkan penurunan konsisten setelah epoch ke-16 dan mencapai titik minimum sebesar 0.0349. Grafik akurasi memperlihatkan peningkatan pesat di awal pelatihan, dengan *training accuracy* tertinggi sebesar 99.98% pada epoch ke-25. Sementara itu, *validation accuracy* tertinggi sebesar 99.00% diperoleh pada epoch ke-18, meskipun terjadi fluktuasi ringan. Dengan *early stopping*, pelatihan berhenti pada epoch ke-35 dengan akurasi akhir sebesar 99.95% (latih) dan 99.0% (validasi).




Gambar 9. Grafik model *loss* dan model *accuracy* pada model VGG19.

Evaluasi akhir menunjukkan bahwa model memperoleh testing accuracy sebesar 99.0%. Model secara konsisten menunjukkan performa tinggi dalam semua metrik evaluasi. Untuk kategori No Tumor, model memperoleh precision, recall, dan f1-score sebesar 1.000. Akurasi klasifikasi untuk Glioma, Meningioma, dan Pituitary adalah masing-masing 96.8%, 99.6%, dan 99.6%. F1-score tertinggi tercatat pada kategori Pituitary (0.9960), sementara Glioma mencatat f1-score sebesar 0.9837. Meskipun precision pada kelas *Meningioma* sedikit lebih rendah (0.9651), nilai recall yang sangat tinggi (0.9960) mengindikasikan efektivitas deteksi yang sangat baik. Rata-rata makro dan tertimbang dari precision, recall, dan f1-score semuanya berada di atas 0.99.



Gambar 10. Ringkasan proses *training* pada model VGG19.

Berdasarkan *confusion matrix*, semua sampel *No Tumor* (250 data) diklasifikasikan dengan tepat. Sebanyak 242 dari 250 data *Glioma* dikenali dengan benar, dengan delapan prediksi salah sebagai *Meningioma*. Untuk *Meningioma* dan *Pituitary*, masing-masing 249 sampel berhasil diklasifikasikan dengan benar, dan masing-masing memiliki satu kesalahan klasifikasi satu sama lain.



Gambar 11. Confusion matrix model VGG19.

Model **EfficientNetV2S** menunjukkan keunggulan yang konsisten, tidak hanya dalam hal akurasi klasifikasi yang lebih tinggi, tetapi juga dalam efisiensi jumlah parameter dibandingkan dengan VGG19. Temuan ini sejalan dengan studi oleh Tan dan Le (2021) yang menegaskan bahwa arsitektur EfficientNet memiliki keunggulan dalam hal skalabilitas dan efisiensi, sehingga optimal digunakan untuk berbagai tugas klasifikasi citra. Tabel berikut menyajikan perbandingan performa ketiga model yang diuji dalam penelitian ini.

Tabel 1. Perbandingan akurasi model	
Model	Akurasi Testing
EfficientNetV2S	99.2%
ResNet152V2	98.8%
VGG19	99.0%

Dari sisi kualitas pelatihan, ketiga model menunjukkan stabilitas yang baik selama proses validasi dan pengujian, dengan nilai *loss* yang relatif rendah dan minim fluktuasi. Visualisasi kurva pembelajaran menunjukkan pola konvergensi yang konsisten tanpa indikasi *underfitting* maupun *overfitting* yang signifikan. Secara praktis, temuan ini memperkuat potensi penerapan **EfficientNetV2S** sebagai komponen utama dalam sistem pendukung keputusan klinis berbasis kecerdasan buatan. Keunggulan model ini dalam mencapai akurasi tinggi dengan kebutuhan komputasi yang rendah menjadikannya kandidat ideal untuk diimplementasikan pada fasilitas layanan kesehatan dengan

keterbatasan infrastruktur komputasi. Dengan demikian, penelitian ini membuka peluang baru bagi pengembangan sistem klasifikasi tumor otak berbasis AI yang lebih terjangkau dan efisien.

KESIMPULAN

Penelitian ini berhasil mencapai tujuannya dengan membandingkan kinerja arsitektur CNN *pre-trained* EfficientNetV2S, ResNet152V2, dan VGG19 untuk klasifikasi tumor otak berdasarkan citra MRI. Hasilnya menunjukkan bahwa **EfficientNetV2S adalah model yang paling optimal**, tidak hanya karena mencapai akurasi tertinggi sebesar **99,2%**, tetapi juga karena efisiensinya dalam penggunaan parameter dan komputasi dibandingkan dengan ResNet152V2 dan VGG19. Dengan demikian, EfficientNetV2S terbukti lebih skalabel dan efektif dalam tugas klasifikasi citra MRI tumor otak ini.

Dampak signifikan dari penelitian ini adalah penyediaan rekomendasi arsitektur model yang lebih optimal untuk mendukung pengembangan sistem diagnosis berbasis AI di bidang radiologi. Ke depannya, eksplorasi lebih lanjut dapat mencakup teknik augmentasi lanjutan, *domain adaptation*, atau integrasi dengan data multimodal untuk meningkatkan kemampuan generalisasi model pada populasi pasien yang lebih luas. Berdasarkan temuan ini, **EfficientNetV2S sangat layak direkomendasikan** sebagai pilihan paling optimal untuk sistem pendukung keputusan klinis, mengingat kemampuannya mencapai akurasi sangat tinggi dengan kebutuhan komputasi yang lebih rendah.

UCAPAN TERIMA KASIH

Puji syukur kami panjatkan ke hadirat Tuhan Yang Maha Esa, atas anugerah dan penyertaan-Nya, sehingga kami bisa mengerjakan serta menyelesaikan penelitian ini dengan lancar. Kami juga ingin mengucapkan terima kasih banyak kepada Bapak Windra Swastika, S.Kom., MT., Ph.D., selaku Dosen Pembimbing kami atas bimbingan dan dukungan yang telah diberikan selama penelitian ini. Tak lupa, kami juga mengapresiasi para penulis jurnal yang karyanya menjadi dasar penting studi ini, serta kepada penyedia data yang telah memungkinkan kami melakukan analisis ini.

DAFTAR PUSTAKA

- Abd-Ellah, M. K., Awad, A. I., Khalaf, A. A. M., & Hamed, H. F. A. (2019). A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned. *Magnetic Resonance Imaging*, 61, 300–318. <https://doi.org/https://doi.org/10.1016/j.mri.2019.05.028>
- Amarnath, A., Al Bataineh, A., & Hansen, J. A. (2024). Transfer-Learning Approach for Enhanced Brain Tumor Classification in MRI Imaging. *BioMedInformatics*, 4(3), 1745–1756. <https://doi.org/10.3390/biomedinformatics4030095>
- Bilal, M., Maqsood, M., Yasmin, S., Hasan, N. U., & Rho, S. (2022, February). A transfer learning-based efficient spatiotemporal human action recognition framework for long and overlapping action classes. *The Journal of Supercomputing*, 78, 2873–2908. <https://doi.org/10.1007/s11227-021-03957-4>
- Global Cancer Observatory. (2022). *Population Factsheets*. Retrieved July 2025, from Cancer Today: <https://gco.iarc.who.int/media/globocan/factsheets/populations/360-indonesia-fact-sheet.pdf>
- Muftic, F., Kadunic, M., Musinbegovic, A., Almisreb, A. A., & Jaafar, H. (2024, December). Deep learning for magnetic resonance imaging brain tumor detection: evaluating ResNet, EfficientNet, and VGG-19. *International Journal of Electrical and Computer Engineering (IJECE)*, 14(6), 6360–6372. <https://doi.org/10.11591/ijece.v14i6.pp6360-6372>
- Nair, A., Ong, W., Lee, A., Leow, N. W., Makmur, A., Ting, Y. H., Lee, Y. J., Ong, S. J., Tan, J. J. H., Kumar, N., & Hallinan, J. T. P. D. (2025). Enhancing Radiologist Productivity with Artificial Intelligence in Magnetic Resonance Imaging (MRI): A Narrative Review. *Diagnostics*, 15(9). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/diagnostics15091146>
- Nickparvar, M. (2021). *Brain Tumor MRI Dataset*. <https://doi.org/10.34740/KAGGLE/DSV/2645886>
- S., V., & T R, G. B. (2021). A Convolutional Neural Network Classifier VGG-19 Architecture for Lesion Detection and Grading in Diabetic Retinopathy Based on Deep Learning. *Computers, Materials & Continua*, 66(1), 827–842. <https://doi.org/10.32604/cmc.2020.012008>
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2: Smaller Models and Faster Training*. <http://arxiv.org/abs/2104.00298>

