

Klasifikasi Tumor Otak pada gambar Magnetic Resonance Images (MRI) dengan Pendekatan Pembelajaran Mendalam

Rahmad Rudiansyah Siregar^{1)*}, Amir Mahmud Husein²⁾

^{1,2)} Universitas Prima Indonesia, Fakultas Sains dan Teknologi, Program Studi Teknik Informatika

Received: 11 July 2024

Accepted: 25 July 2024

Published: 28 July 2024



*rrudiansyahsiregar@gmail.com

Kata Kunci: Tumor, MRI, Klasifikasi Tumor, ImageNet

DSI: Jurnal Data Science Indonesia is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak : Tumor otak adalah salah satu penyakit paling mematikan dan kompleks yang mempengaruhi jutaan orang di seluruh dunia, sehingga klasifikasi tumor otak yang akurat sangat penting untuk pengobatan yang efektif. Diagnosis dan pengobatan tumor otak sangat menantang, dan kurangnya diagnosis yang akurat dan tepat waktu sering kali menyebabkan hasil akhir yang buruk bagi pasien. Metode diagnostik saat ini, seperti MRI dan CT scan, seringkali tidak memadai untuk klasifikasi tumor otak secara akurat. Keputusan diagnostik sangat bergantung pada interpretasi pemindaian magnetic resonance imaging (MRI). Dalam penelitian, penerapan berbagai model CNN VGG16, Xception, MobileNet dan ResNet50 digunakan untuk klasifikasi tumor otak pada kumpulan dataset 4 kelas yaitu glioma, meningioma, notumor dan pituitary. Semua model di uji dengan berbagai percobaan eksperimental dan hasil pengujian menunjukkan bawah model Xception menghasilkan akurasi terbaik dibandingkan model lainnya.

PENDAHULUAN

Tumor otak adalah kondisi pertumbuhan sel yang tidak teratur dan tidak terkontrol di jaringan otak dan sekitarnya. Meski demikian, tumor otak belum tentu berkembang menjadi tumor ganas atau kanker. Tumor otak dibagi menjadi stadium 1 hingga 4. Pengelompokan didasarkan pada perilaku tumor. Misalnya diukur dengan laju pertumbuhan dan penyebarannya. Tumor otak stadium 1 dan 2 tergolong jinak dan tidak berpotensi menjadi ganas. Stadium 3 dan 4 sering disebut dengan tumor otak ganas[1]. Tanda-tanda tumor otak antara lain sakit kepala terus-menerus, kejang, masalah penglihatan, masalah keseimbangan, perubahan kognitif, dan perubahan kepribadian. Gejala bervariasi tergantung pada jenis, lokasi, dan ukuran tumor. Penyakit ini memerlukan perhatian, karena menurut data statistik dari Central Brain Tumor Registry of the United States (CBTRUS) lebih dari 700.000 orang menderita tumor otak stadium awal. Selain itu, penyakit ini berdampak negatif terhadap pasien dan keluarganya. Oleh karena itu, deteksi dini sangat penting untuk meningkatkan prognosis[2].

Pengobatan standar untuk tumor otak seperti Radiasi ultraviolet, bahan kimia, dan prosedur pembedahan seperti biopsi umumnya digunakan dalam mengidentifikasi dan menangani lesi otak. Pendekatan diagnostik tumor otak dengan teknik pencitraan, termasuk magnetic resonance imaging (MRI), computerized tomography (CT) scan menimbulkan beberapa tantangan. MRI dan CT scan memberikan gambaran otak yang detail dan beresolusi tinggi, keduanya memerlukan keahlian khusus dan seringkali memakan waktu, rentan terhadap kesalahan dan bersifat subjektif terhadap variabilitas[3]. MRI menggunakan medan magnet dan gelombang radio, sedangkan CT scan menggunakan sinar-X untuk mendeteksi tumor otak [4]. Namun, metode konvensional mempunyai beberapa keterbatasan, sedangkan teknik pencitraan mahal dan memakan waktu. Sehingga sulit dilakukan pada pasien yang memerlukan pemindaian lanjutan secara berkala[5]. Selain itu, keakuratan teknik pencitraan ini dapat dipengaruhi oleh ukuran dan lokasi tumor serta keberadaan jaringan di sekitarnya. Ada kemungkinan hasil yang salah yang diwakili oleh matriks konfusi model. Hal ini dapat menyebabkan diagnosis yang salah dan pengobatan yang tertunda[6].

Kategorisasi tumor otak penting untuk mengevaluasi tumor serta menentukan pilihan pengobatan

berdasarkan klasifikasinya[7]. Untuk mengidentifikasi tumor otak, metode pencitraan MRI digunakan secara luas karena kualitas gambarnya yang lebih baik dan faktanya MRI tidak menggunakan radiasi pengion[4], [8]–[11]. Beberapa penelitian telah mengeksplorasi penerapan teknik pembelajaran mendalam untuk mendeteksi tumor otak menggunakan gambar MRI, misalnya [12] mengusulkan transfer learning model EfficientNet, ResNet, VGG16, dan Inception untuk prediksi tingkat tumor. Mereka berhasil mencapai akurasi 97%, secara akurat membedakan glioma tingkat rendah (LGG) dan glioma tingkat tinggi (HGG). Penerapan Convolutional neural networks (CNN) dalam beberapa tahun terakhir ini, memainkan peran penting dalam mendeteksi [6], [13], [14], klasifikasi [2], [3], [13], [15] dan segmentasi [8], [16]–[18] tumor otak, kombinasi CNN dengan transfer learning menghasilkan kinerja yang signifikan untuk menghasilkan deteksi dan klasifikasi tumor otak yang lebih andal dan tepat sehingga dapat membantu dokter dalam mendiagnosis tumor otak dengan lebih akurat dan tepat waktu.

Dalam penelitian ini diusulkan analisis komprehensif penerapan CNN dengan lima model pre-trained transfer learning yaitu VGG16, Xception, MobileNet dan ResNet50. Setiap model memiliki arsitektur dan jumlah parameter yang berbeda.

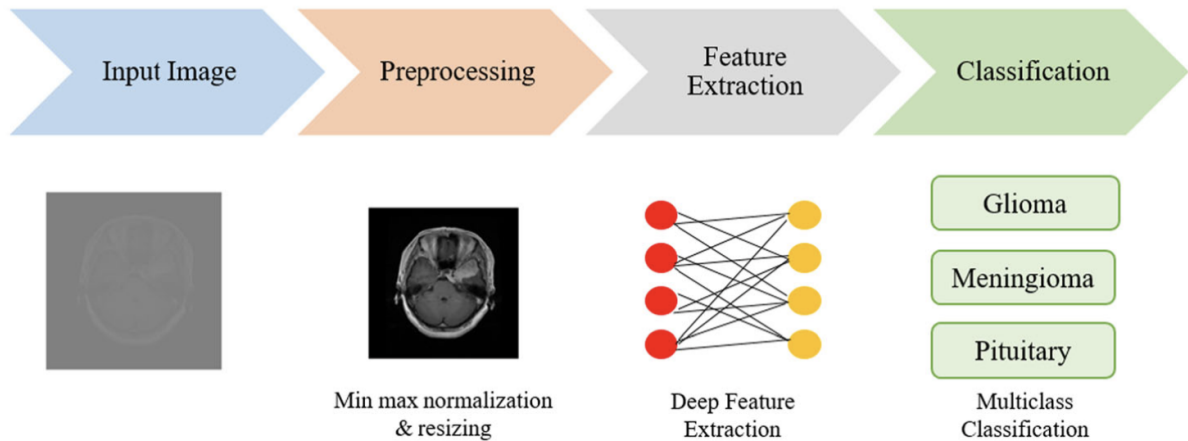
TINJAUAN LITERATUR

Dalam kemajuan terkini dalam analisis citra medis, Convolutional Neural Networks (CNN) memainkan peran penting dekade ini, hal ini didukung karena unggul dalam menangkap fitur-fitur lokal melalui operasi konvolusinya. Beberapa hasil penelitian terbaru penerapan model ini seperti Rasheed, Z et al[3] mengusulkan CLAHE peningkatan gambar, khususnya penajaman berbasis Gaussian-blur dan Ekualisasi Histogram Adaptif dan menghasilkan akurasi klasifikasi sebesar 97,84%, tingkat keberhasilan presisi sebesar 97,85%, tingkat perolehan kembali sebesar 97,85%, dan skor F1 sebesar 97,90%, selain itu Raghuvanshi, S et al [1] mengusulkan arsitektur model VGG16, dan model pembelajaran mendalam lainnya pada data multistate di otak. Hasilnya menunjukkan bahwa model pembelajaran mendalam dapat memberikan akurasi dan efisiensi tinggi dalam deteksi tumor otak di luar teknik pencitraan untuk juga membahas aplikasi klinis model ini, termasuk membantu ahli radiologi dalam diagnosis otak dan meningkatkan hasil pasien.

Selama dekade terakhir, beberapa metode telah diusulkan untuk klasifikasi tumor otak berdasarkan pada penyempurnaan model CNN canggih yang ada, seperti AlexNet, VGG16, ResNets, Inception, DenseNets, dan Xception, yang telah terbukti berhasil untuk berbagai tugas visi [20]–[25]. Model CNN yang telah dilatih sebelumnya berdasarkan konvolusi lokal menunjukkan kinerja yang sangat baik dalam klasifikasi tumor otak di berbagai kumpulan data.

METODE PENELITIAN

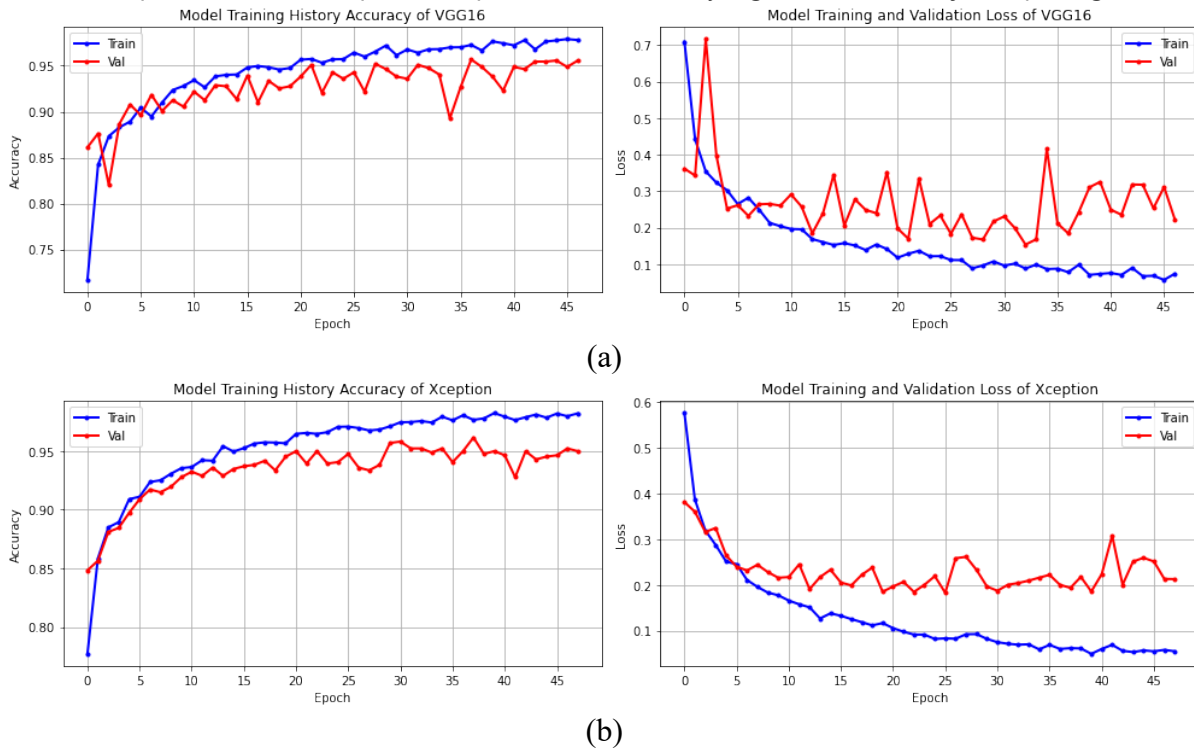
Pada penelitian ini menggunakan dataset gambar MRI tumor otak, kemudian di terapkan pada kerangka kerja berdasarkan penggunaan metode Convolutional Neural Networks (CNN) berdasarkan model pre-trained transfer learning yaitu VGG16, Xception, MobileNet dan ResNet50, untuk pelatihan dan pengujian klasifikasi tumor otak. Kerangka kerja model yang diusulkan diilustrasikan pada gambar 1. Pertama, data uji gambar dari dataset MRI tumor otak digabungkan ke dalam masing- masing folder training dan testing. Kedua folder terdiri dari 405 gambar kasus tanpa tumor, 300 "glioma", 306 "meningioma", dan 300 tumor "pituitary". Selanjutnya, dilakukan pre-processing terhadap data uji gambar dengan melakukan rotasi, penambahan kontras serta penghilangan noise pada gambar. Kemudian data uji gambar diuji untuk diproses agar dapat mendeteksi pasien yang mengidap tumor otak menggunakan jaringan transfer learning yakni VGG16, Xception, MobileNet, dan ResNet50. Dalam langkah ini, dilakukan implementasi dengan algoritma CNN terhadap beberapa kovolusi untuk mengevaluasi dan memantau fitur potensial agar bertindak sebagai pengklasifikasi dengan fitur yang diekstrak dan mengevaluasi probabilitas untuk objek pada gambar.

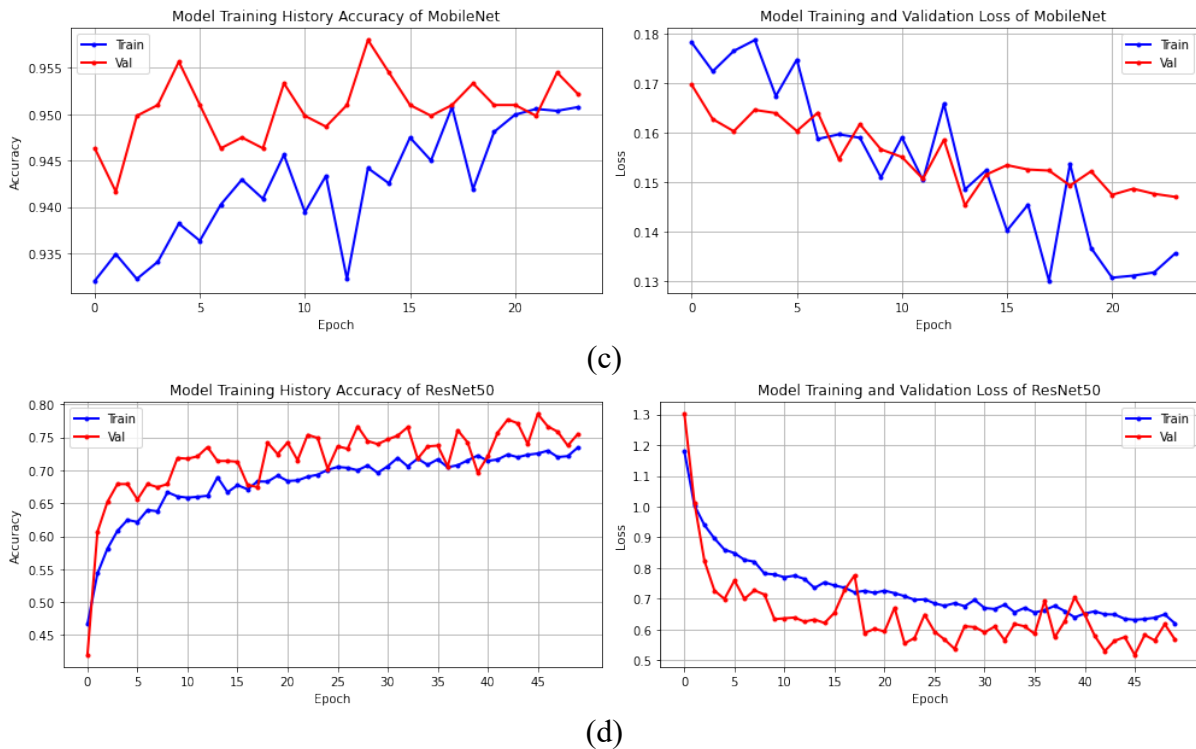


Untuk eksperimen, data dibagi secara acak menjadi 787 set pelatihan dan 524 set pengujian. Namun gambar memiliki perbedaan signifikan dalam distribusi kelas antara kedua set. Perbedaan ini menghadirkan tantangan bagi model CNN untuk melakukan generalisasi dari model yang dilatih ke set pengujian. Selain itu, kedua kelompok tersebut menunjukkan ketidakseimbangan kelas. Untuk pelatihan, set validasi sebesar 15% dari set pelatihan diambil sampelnya secara acak dengan distribusi kelas yang serupa dengan set pelatihan

HASIL PENELITIAN

Proses pelatihan terhadap model VGG19, Xception, MobileNet dan Resnet50 yang digunakan pada data sampel akan distandarisasi ke resolusi 240 x 240 piksel sehingga dapat diproses dengan baik oleh model yang telah dilatih sebelumnya. Dengan mempertahankan konten dan fitur gambar selama penskalaan, upaya komputasi berkurang selama pelatihan, selain itu juga menghasilkan keseimbangan antara kejelasan gambar dan efisiensi pemrosesan. Hasil pelatihan pada semua model yang diusulkan ditunjukkan pada gambar 2.

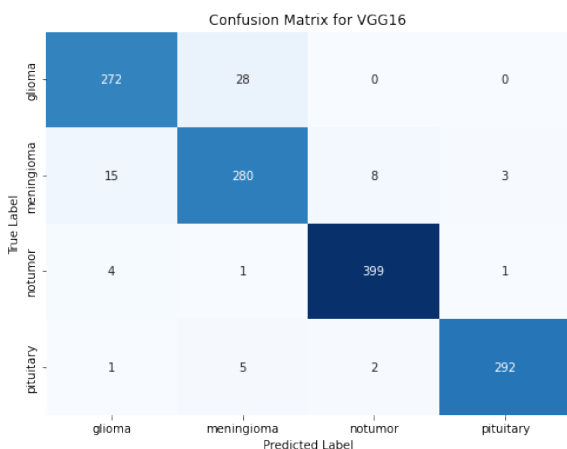




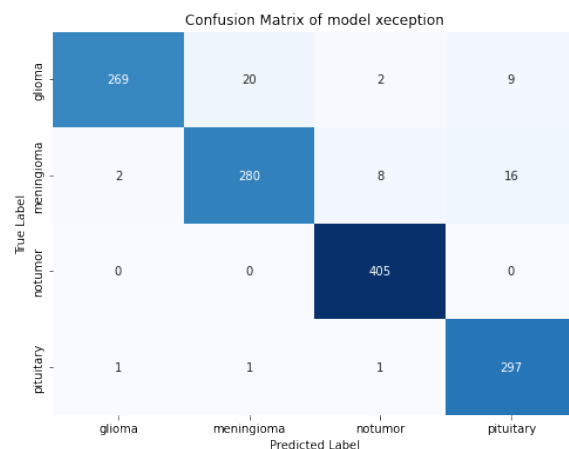
Gambar 2 Valisasi akurasi dan kerugian model (a) VGG16, (b) xception, (c) MobileNet dan (d) RestNet50. Percobaan ini dilakukan dalam 50 epoch, dengan ukuran batch 32. Dalam validasi akurasi model VGG16, validasi akurasi awal di bawah 0,85, kemudian meningkat saat epoch meningkat yang mencapai 0.95%, sedangkan validasi kerugian awal dibawah 0.5, tetapi berkurang di bawah 0.2 pada epoch 25. Hampir semua model terjadi perubahan pada validasi akurasi dan valisasi kerugian. Terdapat tren peningkatan pada valisasi akurasi dan validasi kerugian pada masing-masing model yang diusulkan.

Tabel 1 Tabel Hasil perbandingan model


| Model | Accuracy |
|-----------|----------|
| VGG16 | 0.92 |
| Xception | 0.95 |
| MobileNet | 0.92 |
| Resnet50 | 0.77 |




(a)



(b)



(c)



(d)

Gambar 2 Matrik Konfusi (a) VGG16, (b) xception, (c) MobileNet dan (d) ResNet50

Validitas semua model CNN yang diusulkan telah diuji melalui berbagai penilaian eksperimental. Lingkungan pemrograman Python dengan dukungan GPU digunakan untuk melakukan semua evaluasi eksperimental. Berbagai ukuran kinerja, seperti akurasi, presisi, recall, dan skor F1, digunakan untuk membandingkan kinerja model yang disarankan. Parameter ini dievaluasi menggunakan matriks konfusi yang ditunjukkan pada gambar 2 sedangkan hasil perbandingan akurasi semua model dapat dilihat pada tabel 1. Berdasarkan pada tabel 1 dapat dilihat bahwa model xception memiliki kinerja terbaik dengan tingkat akurasi 0.95% dibandingkan model VGG16 dengan akurasi sebesar 0.92%, kemudian MobileNet dan ResNet50.

PEMBAHASAN

Hasil analisis pada semua model yang diusulkan dengan menggunakan model terlatih ImageNet dievaluasi berdasarkan nilai akurasi yang ditunjukkan pada tabel 1. Meskipun hasil ini menjanjikan, sangat penting untuk memvalidasi model pada kumpulan data yang lebih luas dan rentang kondisi klinis yang lebih luas untuk memastikan keandalannya di berbagai skenario. Pertama, menginisialisasi semua model dengan bobot dari dataset ImageNet. Kemudian, menambahkan lapisan tambahan, termasuk lapisan atas dan lapisan yang terhubung sepenuhnya, untuk memungkinkan klasifikasi tumor. Selanjutnya melakukan berbagai pengujian untuk menilai ketahanan model yang telah disetel dengan baik dibandingkan dengan model lain yang telah dilatih sebelumnya. Terakhir, menganalisis dampak penambahan data pada akurasi pengujian model. Penambahan 3 layer pada semua model menghasilkan pengaruh yang signifikan Dimana layer GlobalAveragePooling2D bertujuan untuk mengurangi beban komputasi pada saat pelatihan, sedangkan layer Dropout menghilangkan beberapa neuron pada setiap langkah dari lapisan sehingga membuat neuron lebih independen sehingga dapat terhindar dari overfitting. Denset bertujuan untuk menghasilkan lapisan keluaran yang mengklasifikasikan gambar ke dalam 1 dari 4 kelas yang memungkinkan. Namun hasil pengujian yang dilakukan masih perlu dievaluasi dengan menambahkan beberapa metode image augmentasion seperti penerapan mode min max atau menambah dataset untuk pelatihan model

KESIMPULAN

Dari analisis kerangka data deteksi tumor, terlihat jelas bahwa model yang diusulkan telah berhasil mencapai klasifikasi tumor dengan kinerja yang luar biasa. Hasil klasifikasi menunjukkan akurasi sekitar 95% pada model xception, kemudian VGG16 dan MobileNet dengan akurasi 92% dan presisi yang sangat tinggi, yang menunjukkan kemahiran model dalam mengenali kasus secara akurat ketika tidak terdapat tumor. Nilai recall yang tinggi semakin menekankan kemampuan model untuk mengidentifikasi sebagian besar kasus negatif yang sebenarnya. Nilai sensitivitas dan spesifisitas menunjukkan kecakapan model dalam meminimalkan positif

palsu dan negatif palsu. Namun, evaluasi lebih lanjut sangat penting untuk memastikan bahwa model tidak mengalami overfitting ketika diterapkan pada kumpulan data yang berbeda atau skenario yang lebih kompleks. Berdasarkan hasil pelatihan dan pengujian pada semua model yang diusulkan Dimana hasil akurasi model telah mencapai akurasi 95%, namun masih terdapat beberapa saran masukan untuk penelitian lanjutan di masa depan, yaitu: Penambahan kumpulan dataset tumor untuk kebutuhan pelatihan sangat penting sehingga penyetulan model untuk meningkatkan akurasi yang lebih baik, menerapkan model lainnya seperti varian dari EfficientNet, Densenet dan penambahan beberapa tulang punggung pada model berbeda dan metode image augmentasi berbeda seperti pendekatan min max atau lainnya masih perlu dipertimbangkan di masa depan.

REFERENCES

- [1] S. Raghuvanshi and S. Dhariwal, "The VGG16 Method Is a Powerful Tool for Detecting Brain Tumors Using Deep Learning Techniques," in *Engineering Proceedings 2023*, Vol. 59, Page 46, Dec. 2023, vol. 59, no. 1, p. 46. doi: 10.3390/engproc2023059046.
- [2] A. A. Asiri et al., "Advancing Brain Tumor Classification through Fine-Tuned Vision Transformers: A Comparative Study of Pre-Trained Models," *Sensors*, vol. 23, no. 18, p. 7913, Sep. 2023, doi: 10.3390/s23187913.
- [3] Z. Rasheed et al., "Brain Tumor Classification from MRI Using Image Enhancement and Convolutional Neural Network Techniques," *Brain Sci.*, vol. 13, no. 9, p. 1320, Sep. 2023, doi: 10.3390/brainsci13091320.
- [4] A. A. Asiri et al., "Exploring the Power of Deep Learning: Fine-Tuned Vision Transformer for Accurate and Efficient Brain Tumor Detection in MRI Scans," *Diagnostics*, vol. 13, no. 12, p. 2094, Jun. 2023, doi: 10.3390/diagnostics13122094.
- [5] T. Shelatkar, D. Urvashi, M. Shorfuzzaman, A. Alsufyani, and K. Lakshmana, "Diagnosis of Brain Tumor Using Light Weight Deep Learning Model with Fine-Tuning Approach," *Comput. Math. Methods Med.*, vol. 2022, 2022, doi: 10.1155/2022/2858845.
- [6] M. A. Khan and H. Park, "A Convolutional Block Base Architecture for Multiclass Brain Tumor Detection Using Magnetic Resonance Imaging," *Electron.*, vol. 13, no. 2, p. 364, Jan. 2024, doi: 10.3390/electronics13020364.
- [7] A. H. Khan et al., "Intelligent Model for Brain Tumor Identification Using Deep Learning," *Appl. Comput. Intell. Soft Comput.*, vol. 2022, pp. 1–10, Jan. 2022, doi: 10.1155/2022/8104054.
- [8] L. M. Ballestar and V. Vilaplana, "MRI Brain Tumor Segmentation and Uncertainty Estimation Using 3D-UNet Architectures," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Dec. 2021, vol. 12658 LNCS, pp. 376–390. doi: 10.1007/978-3-030-72084-1_34.
- [9] W. Wang et al., "A Two-Stage Generative Model with CycleGAN and Joint Diffusion for MRI-based Brain Tumor Detection," *IEEE J. Biomed. Heal. INFORMATICS*, vol. XX, p. 1, Nov. 2023, Accessed: Feb. 21, 2024. [Online]. Available: <https://arxiv.org/abs/2311.03074v1>
- [10] L. Sun, S. Zhang, H. Chen, and L. Luo, "Brain tumor segmentation and survival prediction using multimodal MRI scans with deep learning," *Front. Neurosci.*, vol. 13, no. JUL, p. 810, Aug. 2019, doi: 10.3389/fnins.2019.00810.
- [11] F. Khan et al., "MRI-Based Effective Ensemble Frameworks for Predicting Human Brain Tumor," *J. Imaging 2023*, Vol. 9, Page 163, vol. 9, no. 8, p. 163, Aug. 2023, doi: 10.3390/JIMAGING9080163.
- [12] S. V. Rubio, M. T. García-Ordás, O. G.-O. Olivera, H. Alaiz-Moretón, M.-I. González-Alonso, and J. A. Benítez-Andrades, "Survival and grade of the glioma prediction using transfer learning," *PeerJ Comput. Sci.*, vol. 9, p. e1723, Feb. 2024, doi: 10.7717/peerj-cs.1723.
- [13] G. A. Amran et al., "Brain Tumor Classification and Detection Using Hybrid Deep Tumor Network," *Electron.*, vol. 11, no. 21, p. 3457, Oct. 2022, doi: 10.3390/electronics11213457.
- [14] M. Güler and E. Namlı, "Brain Tumor Detection with Deep Learning Methods' Classifier Optimization Using Medical Images," *Appl. Sci.*, vol. 14, no. 2, p. 642, Jan. 2024, doi: 10.3390/app14020642.
- [15] Y. Çetin-Kaya and M. Kaya, "A Novel Ensemble Framework for Multi-Classification of Brain Tumors Using Magnetic Resonance Imaging," *Diagnostics*, vol. 14, no. 4, p. 383, Feb. 2024, doi:

10.3390/diagnostics14040383.

- [16] A. R. Kavitha and K. Palaniappan, "Brain tumor segmentation using a deep Shuffled-YOLO network," *Int. J. Imaging Syst. Technol.*, vol. 33, no. 2, pp. 511–522, Mar. 2023, doi: 10.1002/ima.22832.
- [17] B. Wang et al., "Brain Tumor Segmentation via Multi-Modalities Interactive Feature Learning," *Front. Med.*, vol. 8, p. 653925, May 2021, doi: 10.3389/FMED.2021.653925/BIBTEX.
- [18] L. Zhao and K. Jia, "Multiscale CNNs for Brain Tumor Segmentation and Diagnosis," *Comput. Math. Methods Med.*, vol. 2016, 2016, doi: 10.1155/2016/8356294.
- [19] Chakrabarty Navoneel, "Brain MRI Images for Brain Tumor Detection | Kaggle," Kaggle, 2019. <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection> (accessed Jul. 10, 2022).
- [20] D. Eng et al., "Automated coronary calcium scoring using deep learning with multicenter external validation," *npj Digit. Med.*, vol. 4, no. 1, pp. 1–13, Jun. 2021, doi: 10.1038/s41746-021-00460-1.
- [21] R. Chelghoum, A. Ikhlef, A. Hameurlaine, and S. Jacquir, "Transfer Learning Using Convolutional Neural Network Architectures for Brain Tumor Classification from MRI Images," vol. 1, Springer International Publishing, 2020, pp. 189–200. doi: 10.1007/978-3-030-49161-1_17.
- [22] A. Al Nahid et al., "A novel method to identify pneumonia through analyzing chest radiographs employing a multichannel convolutional neural network," *Sensors (Switzerland)*, vol. 20, no. 12, pp. 1–18, 2020, doi: 10.3390/s20123482.
- [23] M. Thesis, "A comparative analysis of multi-modal brain-MRI segmentation with 3D deep neural networks," no. July, 2019.
- [24] Y. Sun, L. Li, P. Cong, Z. Wang, and X. Guo, "Enhancement of digital radiography image quality using a convolutional neural network," *J. Xray. Sci. Technol.*, vol. 25, no. 6, pp. 857–868, 2017, doi: 10.3233/XST-17310.
- [25] R. Zhou, S. Hu, B. Ma, and B. Ma, "Automatic Segmentation of MRI of Brain Tumor Using Deep Convolutional Network," *Biomed Res. Int.*, vol. 2022, pp. 1–9, Jun. 2022, doi: 10.1155/2022/4247631.