



Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning

Krisna Nuresa Qodri^{1*}

¹Universitas Muhammadiyah Klaten, Indonesia

*krisna@umkla.ac.id

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 15 April 2024

Revisi Akhir: 19 Mei 2024

Diterbitkan Online: 29 Juni 2024

KATA KUNCI

Brain Tumors, magnetic resonance image (MRI), deep learning, VGG16, ResNet50

KORESPONDENSI

Telepon: +6283840494556

E-mail: krisna@umkla.ac.id

ABSTRACT

Tumor adalah sel yang tumbuh secara abnormal dan tidak terkontrol, sedangkan tumor otak adalah sel yang tumbuh secara abnormal di dalam atau dekat otak. Untuk mengidentifikasi tumor otak, dokter atau tenaga medis biasanya melakukan pemeriksaan radiologi yang umumnya menggunakan gambar resonansi magnetik (MRI). Dari beberapa studi, masing-masing peneliti mengklaim bahwa hasil metode yang mereka usulkan dapat mendeteksi tumor otak dengan akurasi tinggi; namun, masih terdapat kekurangan dalam metode mereka. Makalah ini akan membahas klasifikasi tumor otak berbasis MRI menggunakan deep learning dan transfer learning. Transfer learning memungkinkan untuk berbagai domain, fungsi, dan distribusi yang digunakan dalam pelatihan dan penelitian. Penelitian ini menggunakan dataset publik. Dataset tersebut terdiri dari 3618 gambar, yang dibagi menjadi 2010 gambar otak tanpa tumor dan 1608 gambar otak yang mengandung tumor. Residual Network (ResNet), Xception, dan Visual Geometry Group (VGG) adalah teknik yang akan digunakan dalam makalah ini. Hasil menunjukkan bahwa model ResNet50 mendapatkan akurasi 96% dan VGG16 juga mendapatkan akurasi 96%. Hasil yang diperoleh menunjukkan bahwa transfer learning dapat menangani gambar medis.

1. PENDAHULUAN

Otak berperan penting dalam mengendalikan berbagai fungsi tubuh, seperti pergerakan, persepsi sensorik, dan kemampuan kognitif [1]. Kerusakan otak dapat memicu terjadinya gangguan, misalnya tumbuhnya tumor otak. Tumor ini dibedakan menjadi dua jenis, yaitu tumor jinak dan tumor ganas [2]. Tumor jinak tetap berada di lokasi semula dan mempertahankan bentuk normalnya, sedangkan tumor ganas adalah sel abnormal yang tumbuh di luar kendali dan sering disebut sel kanker. Di Amerika Serikat, diperkirakan sekitar 24.810 orang dewasa akan didiagnosis menderita tumor otak pada tahun 2023 [3]. Jika tidak segera dideteksi dan diobati, penyakit ini bisa berakibat fatal. Ada beberapa metode untuk mendeteksi tumor, seperti *Computed Tomography* (CT), *Positron Emission Tomography* (PET) dan *Magnetic Resonance Imaging* (MRI). Di antara ketiga metode tersebut, MRI dinilai paling aman dan efektif karena memberikan hasil pemeriksaan secara detail tanpa memerlukan gerakan fisik [4].

Diagnosis berbasis komputer (*Computer-assisted diagnosis*, CAD) merupakan teknologi yang berkembang pesat dan menggunakan kecerdasan buatan (AI) untuk membantu mendeteksi tanda-tanda abnormal dari data yang diinputkan [5]. Teknologi CAD dalam pencitraan medis menggabungkan kecerdasan buatan, pembelajaran mesin, pembelajaran mendalam, dan visi komputer. Teknologi ini sangat membantu radiolog dalam mendeteksi kelainan pada citra medis, terutama pada citra MRI. MRI sering dipilih karena memberikan hasil pemeriksaan yang sangat detail serta data resolusi tinggi dengan kontras yang jelas pada jaringan otak. Oleh karena itu, data MRI telah banyak digunakan dalam pengembangan sistem CAD [6]. CAD dapat mendukung radiolog dalam menganalisis citra medis, sehingga waktu yang dibutuhkan untuk menafsirkan hasil gambar medis dapat berkurang. Hal ini sangat menguntungkan dalam meningkatkan hasil perawatan pasien. Sebagai akibatnya, sebuah bidang penelitian telah berkembang, yang berfokus pada analisis citra medis semi-otomatis atau otomatis, dengan menggunakan komputer sebagai topik penelitian dasar [7].

CAD, atau *Computer-Aided Design*, memanfaatkan data medis seperti citra MRI untuk mendeteksi tumor otak. Berbagai

pendekatan telah diterapkan pada citra medis, termasuk pemindaian MRI tumor otak serta tumor dari bagian tubuh lainnya, sebagaimana disebutkan dalam berbagai studi. Algoritma kecerdasan buatan semakin populer dalam mengolah data medis, terutama dalam mendeteksi tumor otak melalui citra MRI. Algoritma yang paling sering digunakan untuk tujuan ini adalah *Convolutional Neural Network* (CNN), yang sering digabungkan dengan teknik transfer learning [6]. CNN dipilih karena kemampuannya memberikan hasil yang lebih baik dibandingkan teknik lain dalam mengelola objek dan pergerakan wajah. CNN dirancang khusus untuk melakukan berbagai tugas seperti klasifikasi gambar, deteksi objek, dan segmentasi, sehingga algoritma *deep learning* ini unggul dalam pengenalan objek. Dengan menerapkan algoritma canggih ini, sistem dapat menganalisis data medis secara efisien dan akurat, yang pada akhirnya membantu dalam deteksi dini kelainan. Ini sangat penting karena dapat secara signifikan meningkatkan hasil pengobatan [8].

Kemajuan teknologi, terutama di bidang kecerdasan buatan dan pembelajaran mesin, memberikan pengaruh besar pada dunia medis, salah satunya adalah pengenalan citra medis. *Convolution Neural Network* (CNN) merupakan salah satu teknik yang digunakan untuk memproses atau mendeteksi tumor otak melalui citra MRI [9]. CNN adalah model *deep learning* yang dirancang untuk memproses data dengan struktur grid seperti gambar, dan terinspirasi oleh organisasi korteks visual pada hewan [10], [11]. CNN dirancang untuk mengekstraksi detail secara lokal pada gambar dan memiliki kemampuan menyimpan informasi spasial. Pendekatan ini sangat efisien, karena memiliki kemampuan bias yang cukup baik [12]. Perkembangan pendekatan ini telah menginspirasi munculnya berbagai jenis arsitektur, seperti *Residual Network* (ResNet), *Network in Network* (NiN), VGG, dan GoogleNet (*Inception module*). *Transfer learning* adalah metode ekstraksi pengetahuan dari berbagai sumber yang diterapkan ke bidang lain [13]. *Transfer learning* memungkinkan penggunaan berbagai domain, fungsi, dan distribusi yang diterapkan dalam pelatihan dan penelitian [13]. Dalam penelitian mereka [14], penggunaan model AlexNet yang telah dilatih menggunakan *dataset* ImageNet dan diterapkan pada *dataset* PASCAL menunjukkan peningkatan signifikan pada kinerja deteksi dan segmentasi [15]. Oleh karena itu, makalah ini akan membahas klasifikasi tumor otak menggunakan teknik *deep learning* dan *transfer learning*.


2. TINJAUAN PUSTAKA

Beberapa studi sebelumnya telah dilakukan terkait deteksi tumor otak menggunakan MRI otak. Metode *Discrete Wavelet Transform* (DWT), *Continuous Wavelet Transform* (CWT), dan *Support Vector Machine* (SVM) digunakan untuk mendeteksi tumor otak [16]. Metode ini menghasilkan hasil yang cukup tinggi, namun masih memiliki kelemahan dalam hal komputasi. Metode CNN dan SVM juga digunakan untuk mengidentifikasi tumor otak [17], di mana hasil untuk SVM cukup tinggi. Meskipun hasilnya cukup tinggi, konfigurasi model yang dibuat tidak disertakan, serta *dataset* yang digunakan tidak dijelaskan, sehingga hasil yang diperoleh menjadi bias. Selain itu, beberapa peneliti mengusulkan penggunaan kalkulus fraksional untuk mendeteksi tumor otak jinak [18]. Metode ini menghasilkan komputasi yang rendah, tetapi akurasi yang diperoleh tidak

dijelaskan. Sebuah studi menjelaskan bahwa metode *Watershed Dynamic Angle Projection - Convolution Neural Network* (WDAPP-CNN) digunakan untuk segmentasi dan klasifikasi tumor otak [19]. Algoritma yang diusulkan mendapatkan hasil yang cukup tinggi untuk sensitivitas dan efisiensi, tetapi tidak fokus pada akurasi, sehingga akurasi tidak diketahui. Penelitian lain mengusulkan metode *Faster R-CNN* untuk mendeteksi tumor otak menggunakan citra MRI otak [20], dan metode ini juga menghasilkan akurasi yang tinggi. Namun, mereka tidak menjelaskan komputasi yang diperoleh. Studi lainnya mengusulkan klasifikasi *Naive Bayes* untuk mendeteksi tumor otak menggunakan citra MRI [21], dan metode ini diklaim 60% lebih baik dibandingkan metode lainnya, meskipun akurasinya tidak lebih dari 84%. Metode *Artificial Neural Network* (ANN) juga diusulkan untuk mendeteksi tumor otak [22], yang menghasilkan hasil yang cukup tinggi. Namun, metode ini tidak dapat secara langsung mendeteksi tumor, pengguna harus memilih setiap tahap mulai dari pra-pemrosesan hingga segmentasi tumor, kemudian klasifikasi dilakukan, dan komputasi tidak dijelaskan. Teknik "*multiple threshold object counting*" diusulkan untuk mendeteksi tumor otak [23], yang diklaim mampu mendeteksi dengan akurasi yang baik, tetapi metode ini hanya dapat mendeteksi posisi tumor dan tidak dapat mengenali apakah citra tersebut mengandung tumor atau tidak. Algoritma SVM diusulkan untuk mendeteksi tumor otak [24], dan diklaim mampu mendeteksi tumor dengan akurasi tinggi, namun hanya mampu mendeteksi posisi tumor, tanpa bisa mengenali citra yang mengandung tumor. Kombinasi algoritma ekstraksi fitur dan CNN-SoftMax diusulkan untuk mendeteksi tumor otak [25], dan metode ini diklaim menghasilkan akurasi yang tinggi, tetapi komputasi yang diperoleh tidak dijelaskan.

Deep learning telah banyak digunakan di berbagai bidang, seperti *omics*, *bioimaging*, pencitraan medis, *brain-machine interfaces*, atau *body-machine interfaces* [26]. Arsitektur Deep Learning yang paling terkenal untuk analisis gambar adalah CNN [26]. Sebuah studi menggunakan arsitektur CNN 3D untuk menentukan keganasan nodul paru-paru [27]. CNN juga diusulkan untuk segmentasi dan diagnosis multi-struktur kardiak [28], serta untuk mendeteksi gangguan kognitif ringan (MCI) pada tahap awal [29]. CNN juga diterapkan untuk mendeteksi inti sel [30]. Beberapa studi di atas menggunakan *deep learning* untuk menyelesaikan masalah masing-masing, dan arsitektur yang digunakan adalah CNN. Metode ini memberikan hasil yang cukup baik. Dari penelitian-penelitian yang disebutkan, banyak yang dilakukan untuk mendeteksi tumor otak, namun masih terdapat beberapa kekurangan. Oleh karena itu, dalam penelitian ini, kami akan tetap membahas deteksi tumor otak. Model yang akan kami gunakan adalah model berbasis arsitektur CNN, dan kami akan menggunakan *transfer learning* untuk mengklasifikasikan tumor menggunakan citra MRI otak. Beberapa model yang akan digunakan dalam penelitian ini termasuk *Residual Network* (ResNet), *Xception*, dan *Visual Geometry Group* (VGG).

Kami menggunakan *dataset* publik untuk penelitian ini. *Dataset* tersebut berisi citra MRI otak, baik citra normal (tanpa tumor) maupun citra abnormal (terdapat tumor). Setiap citra dalam *dataset* memiliki ekstensi .jpg. *Dataset* ini terdiri dari 3618 citra yang terbagi menjadi 2010 citra otak tanpa tumor dan 1608 citra otak dengan tumor. Contoh citra MRI yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Citra MRI Otak

3. METODOLOGI

Dalam penelitian ini, kami menganalisis dan mengevaluasi dampak dari berbagai arsitektur CNN.

3.1. Convolutional Neural Network Architectures (CNN)

Convolutional Neural Network (CNN) adalah salah satu bentuk *deep learning* yang sering digunakan. CNN merupakan algoritma *deep learning* yang dibangun berdasarkan *Multilayer Perceptron* (MLP) untuk memproses data dalam bentuk gambar dua dimensi. Ada beberapa model yang didasarkan pada arsitektur CNN, yaitu:

Residual Network (ResNet) diperkenalkan pada tahun 2016 [31]. ResNet terdiri dari beberapa "*Residual Units*" yang ditumpuk. Xception terdiri dari 36 lapisan konvolusi yang membentuk dasar ekstraksi fungsi dari jaringan. Xception diperkenalkan pada tahun 2017 [32]. Xception adalah tumpukan lapisan konvolusi yang terhubung secara linear, residual, dan terpisah secara kedalaman. Dalam dataset ImageNet, setelah Inception-ResNetV2 dan NasNet Large, Xception meraih peringkat ketiga terbaik. Hal ini memudahkan untuk melakukan perubahan pada model. Arsitektur *Visual Geometry Group* (VGG) diperkenalkan pada tahun 2015 [33]. Hasil akurasi yang diperoleh dari dataset yang mencakup lebih dari 14 juta gambar dalam 1000 kelas di ImageNet menunjukkan bahwa model ini mampu mencapai akurasi sebesar 92,7%. Input dari lapisan pertama berukuran 224 x 224 gambar RGB. VGG menggunakan filter berukuran 3x3 dibandingkan dengan filter yang lebih besar. VGG menerapkan Multi-Scale untuk pelatihan dan pengujian. Selain menggunakan pengujian Multi-Scale, VGG juga menerapkan pengujian dens. Tingkat kesalahan dapat diturunkan sebesar 6,8%.

3.2. Pre-trained CNN

Kami mengadopsi tiga arsitektur CNN mendalam, yaitu ResNet50, Xception, dan VGG16 sebagai ekstraktor fitur dari metode yang diusulkan untuk deteksi tumor berdasarkan citra MRI otak. Model ini telah dilatih menggunakan citra alami (ImageNet) dan dapat diperluas untuk transisi komputasional pembelajaran guna menghilangkan fitur diskriminatif dari citra biomedis [41].

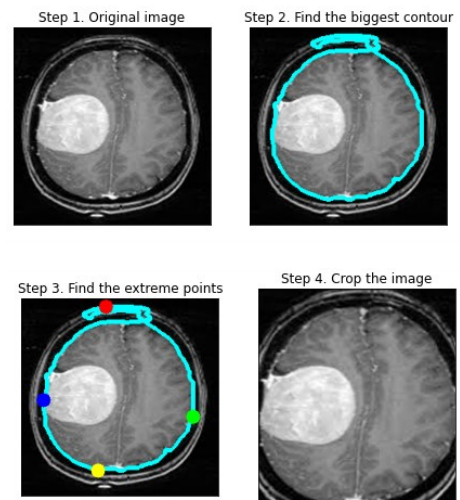
3.3. Transfer Learning

Transfer learning adalah pengetahuan yang diambil dari sumber yang berbeda dan diterapkan ke bidang lain [13]. *Transfer learning* memungkinkan berbagai domain, fungsi, dan distribusi yang digunakan dalam pelatihan dan penelitian. Dalam penelitian mereka [14], dengan menggunakan AlexNet yang telah dilatih sebelumnya di ImageNet untuk *dataset* PASCAL, hasil kinerja deteksi dan segmentasi meningkat secara signifikan. Hasil serupa juga diperoleh dalam studi lain [34], [35]. Dalam penelitian tersebut, mereka menggunakan *transfer learning* dan mampu meningkatkan efisiensi model yang diusulkan. Berdasarkan beberapa studi yang menunjukkan kinerja luar biasa setelah menerapkan *transfer learning*, kami percaya bahwa dengan mempertimbangkan variasi dalam citra, CNN yang sepenuhnya dilatih di ImageNet masih dapat ditransfer untuk melakukan pengenalan menggunakan citra medis.

4. HASIL DAN PEMBAHASAN

Pada bagian ini, kami akan membandingkan dan mengevaluasi kinerja enam model CNN (ResNet50, Xception, dan VGG16) untuk mendeteksi tumor otak menggunakan citra MRI otak dengan memanfaatkan sebuah dataset.


Pada tahap awal, kami melakukan pra-pemrosesan pada citra MRI otak. Pada tahap ini, kami menormalkan data dengan memotong dan mengubah ukuran citra. Gambar 2 menunjukkan hasil sebelum dan setelah pemotongan dan perubahan ukuran citra. Gambar 3 dan Gambar 4 menampilkan citra setelah dipotong dan diubah ukurannya.



Gambar 2. Proses pemotongan citra




Gambar 3. Citra MRI otak tanpa tumor




Gambar 4. Citra MRI otak dengan tumor

Gambar 2 menjelaskan cara memotong citra. Langkah pertama (Langkah 1) adalah menyiapkan citra. Kemudian, langkah kedua (Langkah 2) adalah mencari kontur terbesar. Langkah ketiga (Langkah 3) adalah menemukan titik ekstrem berdasarkan kontur terbesar. Akhirnya, langkah terakhir (Langkah 4) adalah memotong citra sesuai dengan titik ekstrem yang ditemukan. Selanjutnya, kami melakukan augmentasi data. Tujuan dari augmentasi data adalah untuk meningkatkan jumlah data dari data "pelatihan". Kami menggunakan "transformasi acak" dengan rentang rotasi sebesar 30. Gambar 5 menunjukkan hasil dari data yang telah diaugmentasi.




Gambar 5. Hasil dari proses augmentasi citra

Selanjutnya, kami membagi dataset dengan konfigurasi: 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Kemudian, kami membangun model untuk setiap arsitektur (ResNet50, VGG16, dan Xception) dengan konfigurasi: kami menggunakan ukuran batch pelatihan sebesar 32, ukuran batch validasi sebesar 16, jumlah epoch sebanyak 100, jenis pooling "max", bobot "imagenet", dan untuk optimizer kami menggunakan "RMSprop". Gambar 6 hingga Gambar 15 menunjukkan hasil dari setiap model. Gambar 8 adalah grafik dari model ResNet50.




Gambar 6. Hasil training dan validasi menggunakan ResNet50

Model ResNet memperoleh hasil yang tinggi pada pelatihan dan validasi. Akurasi pelatihan mencapai 99% dan akurasi validasi mencapai 96%. Grafik untuk model VGG16 dapat dilihat pada Gambar 7.



Gambar 7. Hasil training dan validasi menggunakan VGG16

Gambar 7 merupakan tampilan grafik yang diperoleh dari pelatihan dan validasi deteksi tumor otak menggunakan MRI dengan model VGG16. Hasil yang diperoleh oleh model VGG16 mencapai 97% untuk akurasi pelatihan dan 97% untuk akurasi validasi. Kemudian hasil untuk percobaan menggunakan Xception dapat di lihat pada Gambar 8.



Gambar 8. Hasil training dan validasi menggunakan Xception

Model Xception juga memperoleh hasil yang rendah baik pada pelatihan maupun validasi. Akurasi pelatihan yang diperoleh oleh model ini adalah 74%, sementara akurasi validasi mencapai 73%. Hasil untuk setiap model dapat dilihat pada Tabel I.

Tabel 1. Hasil Akurasi Tiap Model

No	Model	Training Accuracy	Validation Accuracy	Test Accuracy
1	ResNet50	99%	96%	85%
2	VGG16	97%	96%	85%

3	Xception	74%	73%	69%
---	----------	-----	-----	-----

Tabel 1 menunjukkan hasil akurasi dari setiap model. ResNet50 memperoleh akurasi tertinggi untuk pelatihan, tetapi untuk akurasi validasi dan pengujian, model ResNet50 dan VGG16 memiliki akurasi tertinggi.

5. KESIMPULAN DAN SARAN

Beberapa teknik telah digunakan untuk mengidentifikasi tumor otak. Beberapa studi menunjukkan bahwa *transfer learning* dapat diterapkan untuk pengenalan data medis, seperti gambar MRI. Hasil yang diperoleh dari setiap model menunjukkan bahwa model VGG16 dan ResNet50 mampu mencapai hasil yang cukup tinggi, di mana akurasi yang diperoleh oleh VGG16 selama pengujian validasi adalah 96%, sedangkan model ResNet50 juga berhasil mendapatkan akurasi 96% pada pengujian validasi. Meskipun ResNet50 dan VGG16 memperoleh hasil akurasi yang tinggi, model Xception mendapatkan hasil yang cukup rendah dibandingkan dengan kedua model yang lain. Hasil-hasil ini menunjukkan bahwa *transfer learning* dapat digunakan untuk pengenalan data medis.

Penelitian selanjutnya adalah dengan meningkatkan jumlah citra dan jumlah label. Hal ini diperlukan untuk mengevaluasi apakah model masih mampu menghasilkan hasil yang lebih baik dengan menggunakan gambar medis lainnya.

DAFTAR PUSTAKA

- [1] M. Husain, "The injured brain," *Nat Neurosci*, vol. 11, no. 9, pp. 985–985, Sep. 2008, doi: 10.1038/nn0908-985.
- [2] T. Sinha, "Tumors: Benign and Malignant," *Cancer Ther Oncol Int J*, vol. 10, no. 3, May 2018, doi: 10.19080/CTOIJ.2018.10.555790.
- [3] Cancer.Net., "Brain Tumor—Statistics ." Accessed: May 09, 2024. [Online]. Available: <https://www.cancer.net/cancer-types/brain-tumor/statistics>
- [4] J. R. Fink, M. Muzi, M. Peck, and K. A. Krohn, "Multimodality Brain Tumor Imaging: MR Imaging, PET, and PET/MR Imaging," *Journal of Nuclear Medicine*, vol. 56, no. 10, pp. 1554–1561, Oct. 2015, doi: 10.2967/jnumed.113.131516.
- [5] B. Halalli and A. Makandar, "Computer Aided Diagnosis - Medical Image Analysis Techniques," in *Breast Imaging*, InTech, 2018. doi: 10.5772/intechopen.69792.
- [6] S. Krishnapriya and Y. Karuna, "Pre-trained deep learning models for brain MRI image classification.," *Front Hum Neurosci*, vol. 17, p. 1150120, 2023, doi: 10.3389/fnhum.2023.1150120.
- [7] S. Bauer, R. Wiest, L.-P. Nolte, and M. Reyes, "A survey of MRI-based medical image analysis for brain tumor studies," *Phys Med Biol*, vol. 58, no. 13, pp. R97–R129, Jul. 2013, doi: 10.1088/0031-9155/58/13/R97.
- [8] L. Pinto-Coelho, "How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications," *Bioengineering*, vol. 10, no. 12, p. 1435, Dec. 2023, doi: 10.3390/bioengineering10121435.
- [9] N. Kumari and L. Gray, "Review of Brain Tumor Segmentation and Classification," *2018 International Conference on Current Trends towards Converging Technologies (ICCTCT)*, pp. 1–6, 2018.
- [10] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol Cybern*, vol. 36, no. 4, pp. 193–202, Apr. 1980, doi: 10.1007/BF00344251.
- [11] D. H. Hubel and T. N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," *J Physiol*, vol. 195, no. 1, pp. 215–243, Mar. 1968, doi: 10.1113/jphysiol.1968.sp008455.
- [12] M. Mahmud, M. S. Kaiser, A. Hussain, and S. Vassanelli, "Applications of Deep Learning and Reinforcement Learning to Biological Data," *IEEE Trans Neural Netw Learn Syst*, vol. 29, no. 6, pp. 2063–2079, 2018, doi: 10.1109/TNNLS.2018.2790388.
- [13] S. J. Pan and Q. Yang, "A Survey on Transfer Learning," *IEEE Trans Knowl Data Eng*, vol. 22, no. 10, pp. 1345–1359, 2010, doi: 10.1109/TKDE.2009.191.
- [14] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Region-Based Convolutional Networks for Accurate Object Detection and Segmentation," *IEEE Trans Pattern Anal Mach Intell*, vol. 38, no. 1, pp. 142–158, Jan. 2016, doi: 10.1109/TPAMI.2015.2437384.
- [15] M. Everingham, S. M. A. Eslami, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "The PASCAL Visual Object Classes Challenge : A Retrospective," *Int J Comput Vis*, vol. 111, no. 1, pp. 98–136, 2015, doi: 10.1007/s11263-014-0733-5.
- [16] M. Gurbină, M. Lascu, and D. Lascu, "Tumor Detection and Classification of MRI Brain Image using Different Wavelet Transforms and Support Vector Machines," in *42nd International Conference on Telecommunications and Signal Processing (TSP)*, 2019, pp. 505–508.
- [17] R. Vinoth and C. Venkatesh, "Segmentation and Detection of Tumor in MRI images Using CNN and SVM Classification," in *2018 Conference on Emerging Devices and Smart Systems (ICEDSS)*, Tiruchengode: IEEE, 2018, pp. 21–25. doi: 10.1109/ICEDSS.2018.8544306.
- [18] S. K. Chandra, "Effective Algorithm For Benign Brain Tumor Detection Using Fractional Calculus," in *TENCON 2018 - 2018 IEEE Region 10 Conference*, Jeju: IEEE, 2018, pp. 2408–2413. doi: 10.1109/TENCON.2018.8650163.
- [19] T. A. Jemimma and Y. J. Vetharaj, "Watershed Algorithm based DAPP features for Brain Tumor Segmentation and Classification," in *2018 International Conference on Smart Systems and Inventive Technology (ICSSIT)*, IEEE, Dec. 2018, pp. 155–158. doi: 10.1109/ICSSIT.2018.8748436.
- [20] R. Ezhilarasi and P. Varalakshmi, "Tumor Detection in the Brain using Faster R-CNN," in *2018 2nd International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC) (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 2018 2nd International Conference on, Palladam: IEEE,

- 2018, pp. 388–392. doi: 10.1109/I-SMAC.2018.8653705.
- [21] D. Divyarnary, “Brain Tumor Detection from MRI Images using Naive Classifier,” in *6th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2020, pp. 620–622.
- [22] H. E. M. Abdalla and M. Y. Esmail, “Brain Tumor Detection by using Artificial Neural Network,” in *2018 International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEEE)*, IEEE, 2018, pp. 1–6.
- [23] M. Nasor and W. Obaid, “MRI Tumor Detection and Localization by Multiple Threshold Object Counting Technique,” in *2018 International Conference on Computer and Applications (ICCA)*, IEEE, 2018, pp. 158–161.
- [24] M. S. Majib and T. M. S. Sazzad, “A Framework To Detect Brain Tumor Cells Using MRI Images,” in *International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, Ankara, Turkey, Turkey: IEEE, 2020, pp. 1–5.
- [25] M. Siar and M. Teshnehlab, “Brain Tumor Detection Using Deep Neural Network and Machine Learning Algorithm,” in *9th International Conference on Computer and Knowledge Engineering (ICCKE)*, Mashhad: IEEE, 2019, pp. 363–368.
- [26] M. Mahmud, M. S. Kaiser, A. Hussain, and S. Vassanelli, “Applications of Deep Learning and Reinforcement Learning to Biological Data,” *IEEE Trans Neural Netw Learn Syst*, vol. 29, no. 6, pp. 2063–2079, Jun. 2018, doi: 10.1109/TNNLS.2018.2790388.
- [27] S. Hussein, P. Kandel, C. W. Bolan, M. B. Wallace, and U. Bagci, “Lung and Pancreatic Tumor Characterization in the Deep Learning Era: Novel Supervised and Unsupervised Learning Approaches,” *IEEE Trans Med Imaging*, vol. 38, no. 8, pp. 1777–1787, 2019, doi: 10.1109/TMI.2019.2894349.
- [28] O. Bernard *et al.*, “Deep Learning Techniques for Automatic MRI Cardiac Multi-structures Segmentation and Diagnosis: Is the Problem Solved?,” *IEEE Trans Med Imaging*, vol. 37, no. 11, pp. 2514–2525, 2018, doi: 10.1109/TMI.2018.2837502.
- [29] T.-E. Kam, H. Zhang, Z. Jiao, and D. Shen, “Deep Learning of Static and Dynamic Brain Functional Networks for Early MCI Detection,” *IEEE Trans Med Imaging*, vol. 32, no. 2, pp. 478–487, 2020, doi: 10.1109/TMI.2019.2928790.
- [30] M. Tofighi, T. Guo, J. K. P. Vanamala, and V. Monga, “Prior Information Guided Regularized Deep Learning for Cell Nucleus Detection,” *IEEE Trans Med Imaging*, vol. 38, no. 9, pp. 2047–2058, 2019, doi: 10.1109/TMI.2019.2895318.
- [31] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas: IEEE, 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [32] F. Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu: IEEE, 2017, pp. 1800–1807. doi: 10.1109/CVPR.2017.195.
- [33] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks For Large-Scale Image Recognition,” in *International Conference on Learning Representations*, San Diego, 2015, pp. 1–14.
- [34] A. Sharif, R. Hossein, A. Josephine, and S. Stefan, “CNN Features off-the-shelf: an Astounding Baseline for Recognition,” in *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Columbus: IEEE, 2014, pp. 512–519. doi: 10.1109/CVPRW.2014.131.
- [35] B. Zhou, A. Lapedriza, J. Xiao, A. Torralba, and A. Oliva, “Learning Deep Features for Scene Recognition using Places Database,” in *Advances in Neural Information Processing Systems 27 (NIPS 2014)*, 2014, pp. 487–495.