

Klasifikasi Tumor Otak pada Citra MRI Menggunakan Transfer Learning EfficientNetB1 dan Visualisasi Grad-CAM

Suyanti¹, Chandy Ophelia S², Lies Aryani³, Chindra saputra⁴, Prayitno⁵,

¹⁻³Sistem Informasi, Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Indonesia

⁴Sistem Komputer, Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Indonesia

⁵Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Indonesia

Email: suyanti272@gmail.com¹, chandyophelia94@gmail.com², liesaryani6@gmail.com³, chindrasaputra@gmail.com⁴, prayitno4704@gmail.com⁵

Alamat: Jl. Jenderal Sudirman, Tambak Sari, Thehok, Kota Jambi, Jambi, 36138

*Penulis Korespondensi: suyanti272@gmail.com

Submitted :
25 February 2026

Revision :
11 Maret 2026

Accepted:
12 Maret 2026

Published:
31 Maret 2026

Abstrak: *Magnetic resonance imaging (MRI)* menyediakan kontras anatomi yang kaya untuk penilaian tumor otak, tetapi interpretasi rutin tetap memerlukan waktu dan ketelitian tinggi. Penelitian ini membangun *pipeline* klasifikasi empat kelas citra MRI otak (glioma, meningioma, pituitary, dan tidak ada tumor) dengan menggabungkan pemotongan area otak otomatis, augmentasi data, serta *transfer learning* menggunakan EfficientNetB1. Hasil eksperimen menunjukkan performa yang sangat kuat dengan raihan akurasi keseluruhan mencapai 0,99 (99%) pada data uji. Secara spesifik, model mencapai skor F1 sebesar 1,00 pada kelas tidak ada tumor, 0,99 pada kelas pituitary, serta 0,98 untuk kelas glioma dan meningioma. Selain laporan kuantitatif, penggunaan visualisasi Grad-CAM membuktikan bahwa prediksi model berlandaskan pada wilayah anatomi yang masuk akal secara klinis. Temuan ini menunjukkan bahwa kombinasi arsitektur yang efisien dan *preprocessing* yang tepat mampu menghasilkan sistem deteksi tumor otak yang akurat sekaligus dapat diinterpretasikan secara visual

Kata kunci: tumor otak, MRI, EfficientNet, transfer learning, Grad-CAM, *pipeline*.

Abstract: *Magnetic resonance imaging (MRI)* provides rich anatomical contrast for brain tumor assessment, yet routine interpretation remains time-intensive and demands high precision. This work develops a pipeline for four-class brain MRI image classification (glioma, meningioma, pituitary tumor, and no tumor) by combining automated brain-region cropping, data augmentation, and transfer learning with EfficientNetB1. Experimental results demonstrate exceptional performance, achieving an overall accuracy of 0.99 (99%) on the test set. Specifically, the model reached an F1-score of 1.00 for the no tumor class, 0.99 for pituitary, and 0.98 for both glioma and meningioma classes. Beyond reporting numerical performance, the study utilizes Grad-CAM heatmaps to verify that predictions rely on clinically plausible regions rather than spurious background cues. These results indicate that an efficiency-oriented backbone, paired with systematic preprocessing, can achieve reliable and interpretable performance for brain tumor classification tasks.

Keywords: brain tumor, MRI, EfficientNet, transfer learning, Grad-CAM, *pipeline*.

1. PENDAHULUAN

Perkembangan terbaru dalam klasifikasi tumor sistem saraf pusat menegaskan bahwa diagnosis modern tidak lagi mengandalkan histologi semata, melainkan mengintegrasikan informasi molekuler untuk meningkatkan konsistensi klasifikasi dan relevansi klinisnya [1]. Perubahan paradigma tersebut berdampak langsung pada praktik klinis karena penentuan subtype yang lebih presisi memengaruhi pilihan terapi, stratifikasi risiko, serta perencanaan tindak lanjut pasien [2]. Dalam konteks ini, MRI menjadi modalitas

utama untuk evaluasi tumor otak karena mampu menggambarkan perbedaan jaringan lunak secara detail tanpa paparan radiasi pengion, sehingga cocok untuk pemantauan berulang [3].

Namun, volume data MRI yang besar dan keragaman tampilan lesi menempatkan beban kognitif yang tinggi pada pembacaan manual dan dapat memunculkan variasi antar pembaca, terutama pada kasus dengan batas lesi yang tidak tegas [3]. Pendekatan *computer-aided* diagnosis berbasis *deep learning* kemudian berkembang pesat karena *CNN* mampu mengekstraksi fitur hierarkis langsung dari citra dan secara konsisten menunjukkan kinerja kuat pada berbagai tugas analisis citra medis [4]. Pada klasifikasi tumor otak, studi-studi terkini memperlihatkan bahwa *CNN* efektif untuk membedakan pola lesi yang kompleks pada MRI, meskipun tantangan seperti kemiripan morfologi antar kelas masih sering muncul [5].

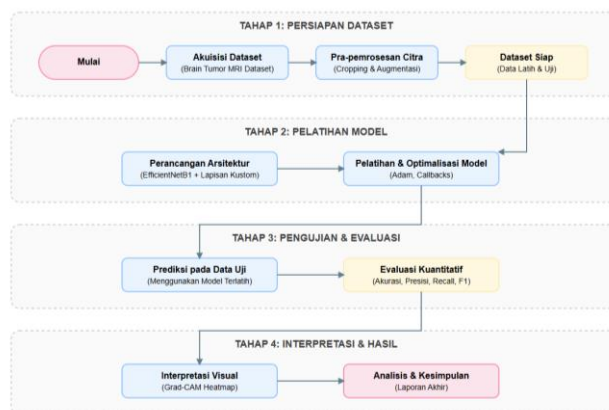
Keterbatasan ukuran dataset berlabel pada citra medis menjadikan *transfer learning* sebagai strategi yang praktis, karena bobot pra-latih dapat mempercepat konvergensi dan meningkatkan performa ketika data pelatihan tidak sebesar dataset natural [5]. Pemanfaatan representasi dari ImageNet, sebagai salah satu benchmark terbesar untuk pembelajaran visual, sering kali menjadi titik awal yang efektif untuk berbagai tugas turunan, termasuk pada ranah medis [6]. Atas pertimbangan efisiensi, *EfficientNet* menawarkan kerangka penskalaan yang seimbang sehingga dapat mencapai akurasi tinggi dengan biaya komputasi yang relatif rendah dibandingkan peningkatan parameter yang tidak terkontrol [7].

Meski performa klasifikasi penting, adopsi di ranah klinis juga menuntut interpretabilitas agar pengguna dapat menilai alasan di balik keputusan model dan mendeteksi kemungkinan bias atau artefak [8]. Grad-CAM merupakan pendekatan yang populer karena menghasilkan peta panas berbasis gradien yang menunjukkan lokasi kontribusi fitur terhadap prediksi kelas target pada CNN, sehingga lebih mudah diaudit secara visual. Penelitian ini menggunakan dataset MRI terbuka untuk mengimplementasikan klasifikasi empat kelas menggunakan *EfficientNetB1* dan mengaitkan hasilnya dengan analisis penjelasan Grad-CAM sebagai langkah menuju model yang tidak hanya akurat, tetapi juga dapat dipercaya [9].

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan dataset citra MRI otak empat kelas (glioma, meningioma, pituitary, dan tidak ada tumor) yang tersedia secara terbuka dan disusun dalam struktur folder per kelas. Berikut ini flowchart alur penelitian

Gambar 1 Alur Penelitian



Penelitian ini menggunakan pendekatan eksperimen untuk mengembangkan model klasifikasi citra MRI tumor otak berbasis deep learning. Secara umum, tahapan penelitian terdiri dari empat tahap utama, yaitu persiapan dataset, pelatihan model, pengujian dan evaluasi, serta interpretasi hasil.

1. Persiapan Dataset

Tahap awal penelitian adalah proses pengumpulan dan persiapan dataset. Dataset yang digunakan berasal dari Brain Tumor MRI Dataset yang berisi citra Magnetic Resonance Imaging (MRI) otak dengan beberapa kategori tumor. Sebelum digunakan dalam proses pelatihan model, citra terlebih dahulu melalui tahap pra-pemrosesan untuk meningkatkan kualitas data. Proses ini meliputi cropping

untuk memfokuskan area citra serta augmentasi data untuk meningkatkan variasi dataset. Setelah tahap pra-pemrosesan selesai, dataset kemudian dibagi menjadi data latih dan data uji.

2. Pelatihan Model

Pada tahap ini dilakukan perancangan dan pelatihan model klasifikasi citra menggunakan arsitektur EfficientNetB1 sebagai model dasar. Model tersebut dimodifikasi dengan menambahkan lapisan klasifikasi pada bagian akhir untuk menyesuaikan dengan jumlah kelas pada dataset. Proses pelatihan dilakukan menggunakan data latih untuk mengoptimalkan parameter model. Selama proses ini, performa model dipantau menggunakan metrik seperti akurasi dan loss untuk memastikan proses pembelajaran berjalan secara optimal.

3. Pengujian dan Evaluasi

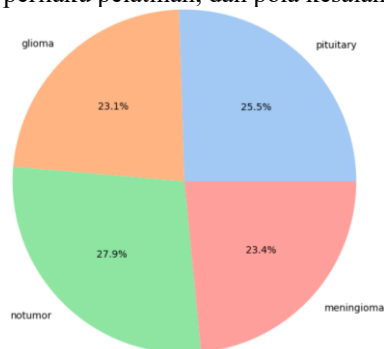
Model yang telah dilatih kemudian diuji menggunakan data uji yang tidak terlibat dalam proses pelatihan. Hasil prediksi model selanjutnya dievaluasi menggunakan beberapa metrik evaluasi klasifikasi, yaitu accuracy, precision, recall, dan F1-score. Metrik tersebut digunakan untuk mengukur kemampuan model dalam melakukan klasifikasi secara akurat dan konsisten.

4. Interpretasi Hasil

Untuk memahami proses pengambilan keputusan model, dilakukan interpretasi visual menggunakan metode Gradient-weighted Class Activation Mapping (Grad-CAM). Metode ini digunakan untuk memvisualisasikan area pada citra yang memberikan kontribusi paling besar terhadap prediksi model. Melalui pendekatan ini, dapat diketahui bagian citra yang menjadi fokus model dalam proses klasifikasi sehingga meningkatkan transparansi dan interpretabilitas model.


3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen beserta pembahasan yang menekankan hubungan antara karakteristik data, desain pipeline, perilaku pelatihan, dan pola kesalahan model.




Gambar 2. Distribusi kelas pada dataset (glioma, meningioma, notumor, pituitary).

Gambar 2 memperlihatkan bahwa jumlah sampel antar kelas berada pada rentang yang relatif berdekatan, sehingga model tidak langsung terdorong untuk selalu memilih kelas tertentu demi mengoptimalkan akurasi. Meski demikian, perbedaan proporsi tetap dapat memengaruhi pembelajaran misalnya kelas dengan sampel sedikit lebih banyak berpotensi memberi sinyal gradien lebih sering selama epoch. Dalam praktiknya, kondisi ini mendorong penggunaan metrik per-kelas pada tahap evaluasi, sebab akurasi agregat dapat menyamarkan penurunan performa pada kelas yang lebih sulit atau lebih jarang.




Gambar 3. Contoh citra MRI untuk masing-masing kelas pada dataset.

Contoh citra pada Gambar 3 menegaskan bahwa perbedaan antar kelas tidak hanya muncul sebagai “ada/tidaknya” massa, melainkan juga perbedaan lokasi, bentuk, intensitas, serta hubungan lesi dengan struktur sekitar. Sebagai ilustrasi, lesi dapat tampak sebagai area hiperintens atau hipointens tergantung sekuens dan kondisi, dan pada beberapa kasus batasnya tidak jelas sehingga terlihat ‘membaur’ dengan jaringan sekitar. Variasi semacam ini mengapa model berbasis CNN dibutuhkan: jaringan harus menggabungkan petunjuk tekstur lokal dan konteks global secara simultan. Pada sisi lain, keragaman ini juga menjelaskan mengapa kelas tertentu lebih mudah tertukar khususnya ketika pola intensitas atau lokasi lesi memiliki kemiripan yang kuat.




Gambar 4. Contoh citra sebelum pemotongan ROI (sebelum cropping).

Perbandingan sebelum dan sesudah cropping pada Gambar 4 menunjukkan perubahan yang substantif pada komposisi masukan: area otak menjadi lebih dominan, sementara ruang kosong di luar kepala yang sebelumnya memenuhi sebagian besar piksel berkurang drastis. Secara pembelajaran, hal ini penting karena CNN belajar dari statistik piksel; jika background terlalu dominan, model berisiko mempelajari ‘shortcut’ yang tidak relevan (misalnya kontras tepi atau pola noise tertentu pada background) alih-alih struktur anatomi. *Cropping* juga membuat skala relatif struktur otak lebih konsisten, sehingga jaringan tidak perlu menghabiskan kapasitas untuk beradaptasi dengan variasi framing yang sebenarnya tidak terkait label. Namun, perlu dicatat bahwa cropping berbasis kontur dapat gagal pada citra dengan artefak kuat atau kontras buruk; karena itu, pemeriksaan kualitas hasil cropping tetap disarankan sebelum pelatihan skala besar.




Gambar 5. Contoh hasil augmentasi citra selama pelatihan.

Gambar 5 menampilkan contoh transformasi yang diterapkan selama pelatihan. Secara konseptual, augmentasi membantu model ‘melihat’ variasi yang mungkin terjadi pada data nyata, seperti pergeseran posisi kepala, perbedaan orientasi, dan variasi framing. Transformasi yang digunakan sengaja dibuat ringan agar label klinis tidak berubah. misalnya rotasi kecil masih merepresentasikan lesi yang sama, hanya dengan orientasi berbeda. Dampak praktisnya adalah model menjadi lebih robust, karena ia tidak mengasosiasikan label hanya pada posisi absolut lesi dalam citra, tetapi juga belajar pola yang lebih stabil seperti tekstur dan bentuk relatif. Pada tahap ini, keseimbangan penting: augmentasi yang terlalu agresif dapat merusak struktur halus yang sebenarnya krusial untuk membedakan kelas.



Gambar 6. Kurva akurasi dan loss pelatihan serta validasi selama epoch.

Kurva akurasi dan loss pada Gambar 6 memperlihatkan konvergensi yang stabil: *loss* menurun tajam pada epoch awal, lalu melandai ketika model mulai mencapai representasi yang memadai untuk membedakan kelas. Jarak antara kurva *training* dan *validation* relatif kecil pada fase akhir, yang mengindikasikan bahwa regularisasi dan strategi penghentian pelatihan bekerja dengan baik dalam mencegah *overfitting*. Pola ini juga menunjukkan bahwa model tidak sekadar menghafal contoh pelatihan; ia mampu mempertahankan performa ketika dihadapkan pada data validasi yang tidak dilihat selama update bobot. Jika jarak *training-validation* membesar pada fase akhir, itu biasanya tanda bahwa model mulai menghafal *noise* atau artefak; pada eksperimen ini, fenomena tersebut tampak terkendali.




Gambar 7. Confusion Matrix

Confusion matrix pada Gambar 7 menunjukkan mayoritas prediksi berada pada diagonal utama, sehingga menegaskan performa model yang sangat baik pada data uji; kesalahan yang muncul relatif kecil dan terutama berupa pertukaran prediksi antara glioma dan meningioma, yang mengindikasikan adanya kemiripan karakteristik visual pada kedua kelas tersebut sehingga pemisahan menjadi lebih menantang bagi model

Tabel 1 menyajikan ringkasan metrik n pada evaluasi data uji.

Kelas	Precision	Recall	F1-score	Support
Glioma	0.99	0.98	0.98	300
Meningioma	0.97	0.98	0.98	306
No tumor	1.00	1.00	1.00	405
Pituitary	0.99	0.99	0.99	300
Akurasi (overall)	-	-	0.99	1311
Macro avg	0.99	0.99	0.99	1311
Weighted avg	0.99	0.99	0.99	1311

Berdasarkan Tabel 1, model klasifikasi menunjukkan performa yang sangat impresif dengan akurasi keseluruhan mencapai 0,99. Kelas "No tumor" berhasil diidentifikasi dengan sempurna (*F1-score 1,00*), yang mengindikasikan bahwa sistem sangat andal dalam membedakan kondisi normal tanpa risiko *false alarm*. Nilai *precision* dan *recall* yang seimbang dan tinggi di seluruh kelas, termasuk skor 0,99 untuk Pituitary serta 0,98 untuk Glioma dan Meningioma, membuktikan kemampuan model dalam meminimalkan kesalahan diagnosis. Hal ini sangat krusial dalam konteks klinis, di mana kesalahan kecil pada Glioma dan Meningioma yang hanya berupa "salah tukar" antar jenis tumor jauh lebih aman dibandingkan kesalahan fatal yang mengategorikan tumor sebagai kondisi normal..



Gambar 9. Visualisasi Grad-CAM pada citra uji

Visualisasi Grad-CAM pada Gambar 9 memperdalam pemahaman tentang ‘alasan’ model. Idealnya, peta panas menyoroti area lesi atau struktur sekitar yang relevan dengan diagnosis, bukan wilayah acak atau pinggiran citra. Pada contoh yang baik, *heatmap* terkonsentrasi pada area yang secara visual tampak abnormal, mengindikasikan bahwa model benar-benar memanfaatkan sinyal yang bermakna. Jika *heatmap* konsisten menyorot tepi kepala, teks *overlay*, atau artefak tertentu, maka perlu dicurigai bahwa model belajar *shortcut*. Dalam penelitian ini, peta yang dihasilkan secara umum menunjukkan fokus yang lebih masuk akal, sehingga mendukung interpretasi bahwa performa tinggi tidak semata-mata berasal dari kebetulan pada background.

4. KESIMPULAN

Implementasi *EfficientNetB1* dengan optimasi ROI dan augmentasi data berhasil menghasilkan model klasifikasi tumor otak yang sangat akurat dengan akurasi 0,99. Model ini menunjukkan performa luar biasa dengan F1-score sempurna 1,00 pada kelas "No tumor", serta skor 0,99 untuk Pituitary dan 0,98 untuk Glioma serta Meningioma. Keunggulan ini diperkuat oleh visualisasi Grad-CAM yang secara akurat menyoroti area lesi secara klinis, memberikan transparansi visual yang memastikan bahwa setiap prediksi didasarkan pada fitur anatomi yang relevan dan dapat diandalkan bagi diagnosis medis. Penelitian lanjutan disarankan menggunakan dataset multi-sumber (berbeda rumah sakit/sekuens MRI) agar model lebih *robust* dan generalisasi meningkat.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Dinamika Bangsa serta pihak-pihak yang telah memberikan dukungan selama proses penyusunan penelitian ini.

DAFTAR PUSTAKA

- [1] D. N. Louis *et al.*, “The 2021 WHO Classification of Tumors of the Central Nervous System: a summary,” *Neuro-Oncology*, vol. 23, no. 8, pp. 1231–1251, Aug. 2021, doi: 10.1093/neuonc/noab106.
- [2] C. Horbinski, T. Berger, R. J. Packer, and P. Y. Wen, “Clinical implications of the 2021 edition of the WHO classification of central nervous system tumours,” *Nat Rev Neurol*, vol. 18, no. 9, pp. 515–529, Sep. 2022, doi: 10.1038/s41582-022-00679-w.
- [3] M. K. Abd-Allah, A. I. Awad, A. A. M. Khalaf, and H. F. A. Hamed, “A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned,” *Magnetic Resonance Imaging*, vol. 61, pp. 300–318, Sep. 2019, doi: 10.1016/j.mri.2019.05.028.
- [4] G. Litjens *et al.*, “A Survey on Deep Learning in Medical Image Analysis,” 2017, doi: 10.48550/ARXIV.1702.05747.
- [5] S. Saeedi, S. Rezayi, H. Keshavarz, and S. R. Niakan Kalhori, “MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques,” *BMC Med Inform Decis Mak*, vol. 23, no. 1, p. 16, Jan. 2023, doi: 10.1186/s12911-023-02114-6.
- [6] H. Listiani, S. N. Asia, S. Sepriano, and L. Judijanto, *Deep Learning: Konsep, Arsitektur, dan Implementasi*. PT. Sonpedia Publishing Indonesia, 2025.
- [7] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” 2019, doi: 10.48550/ARXIV.1905.11946.
- [8] E. Tjoa and C. Guan, “A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI,” *IEEE Trans. Neural Netw. Learning Syst.*, vol. 32, no. 11, pp. 4793–4813, Nov. 2021, doi: 10.1109/TNNLS.2020.3027314.
- [9] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization,” *Int J Comput Vis*, vol. 128, no. 2, pp. 336–359, Feb. 2020, doi: 10.1007/s11263-019-01228-7.
- [10] A. D A, M. S. Shekar, A. Bharadwaj, N. Vineeth, and M. L. Neelima, “Deep Learning in Medical Image Analysis: A Survey,” in *2024 International Conference on Innovation and Novelty in Engineering and Technology (INNOVA)*, Vijayapura, India: IEEE, Dec. 2024, pp. 1–5. doi: 10.1109/INNOVA63080.2024.10847040.
- [11] W. S. Mada Sanjaya, *Deep Learning Citra Medis Berbasis Pemrograman Python-Penerbit Bolabot*. Bolabot, 2023.

- [12] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [13] M. Shafiq and Z. Gu, "Deep Residual Learning for Image Recognition: A Survey," *Applied Sciences*, vol. 12, no. 18, p. 8972, Sep. 2022, doi: 10.3390/app12188972.
- [14] M. K. Insani and D. B. Santoso, "Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan," *jimik*, vol. 5, no. 3, pp. 2612–2622, Sep. 2024, doi: 10.35870/jimik.v5i3.925.
- [15] A. Sasongko, M. S. Maulana, A. Mustopa, and W. Nugraha, "Automatic Wound Image Segmentation with U-Net Model for Smartphone Application," *JEPIN*, vol. 10, no. 2, p. 267, Aug. 2024, doi: 10.26418/jp.v10i2.78548.
- [16] F. Isensee, P. F. Jaeger, S. A. A. Kohl, J. Petersen, and K. H. Maier-Hein, "nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation," *Nat Methods*, vol. 18, no. 2, pp. 203–211, Feb. 2021, doi: 10.1038/s41592-020-01008-z.
- [17] M. Harahap and A. M. Husein, "Penerapan Efficient-Net Dalam Mengklasifikasi Kanker Kulit," *PUBLIS PENERBIT UNPRI PRESS*, vol. 1, no. 1, Jan. 2024, Accessed: Jan. 08, 2026. [Online]. Available: <https://jurnal.unprimdn.ac.id/index.php/isbn/article/view/5405>
- [18] H.-C. Shin *et al.*, "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1285–1298, May 2016, doi: 10.1109/TMI.2016.2528162.
- [19] D. J. Rumala, "Brain Disease Classification in MRI Images Using Deep Learning Based on Deep-Stacked Models and Enhanced Feature Representation," Institut Teknologi Sepuluh Nopember, 2024.
- [20] S. Das and S. Das, "A Comparative Analysis of Optimization Methods for Classification on Various Datasets," 2025.
- [21] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, and F. Shen, "Image Data Augmentation for Deep Learning: A Survey," 2022, *arXiv*. doi: 10.48550/ARXIV.2204.08610.
- [22] Haibo He and E. A. Garcia, "Learning from Imbalanced Data," *IEEE Trans. Knowl. Data Eng.*, vol. 21, no. 9, pp. 1263–1284, Sep. 2009, doi: 10.1109/TKDE.2008.239.
- [23] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.