

KLASIFIKASI TUMOR OTAK PADA CITRA MRI MENGGUNAKAN ARSITEKTUR EFFICIENTNETB3 DAN MOBILENETV3

Mandy Sandra Denny

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara,
Jln. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia
e-mail: *mandy.535210034@stu.untar.ac.id*

ABSTRAK

Tumor otak merupakan penyakit yang dapat terjadi tidak hanya pada orang dewasa, tetapi anak-anak juga dapat terserang penyakit tumor otak. Penyakit ini bersifat menyebar dan dapat menyerang jaringan lain, sehingga lebih baik jika tumor otak dapat dideteksi sejak dini agar dapat dilakukan pengobatan dan mencegah komplikasi bahkan kematian. Untuk mengklasifikasikan jenis tumor otak agar lebih efisien digunakan algoritma *Deep Learning*, yaitu *Convolutional Neural Network* (CNN). Arsitektur CNN yang digunakan adalah EfficientNet-B3 dan MobileNet-V3. Penelitian ini menggunakan dataset *Brain Tumor Classification* dari Kaggle yang berisi 3264 citra tumor otak yang terbagi menjadi 4 kelas, yaitu glioma, meningioma, tanpa tumor, dan pituitary. Tujuan dari penelitian ini adalah membandingkan hasil klasifikasi dari arsitektur CNN yang digunakan, untuk mendapatkan nilai akurasi tertinggi. Penelitian ini menggunakan pendekatan secara kuantitatif untuk mengklasifikasikan tumor otak. Hasil akurasi data latih yang diperoleh dari arsitektur EfficientNet-B3 dan MobileNet-V3 masing-masing sebesar 89.23% dan 90.62%, sedangkan akurasi data uji masing-masing sebesar 87.44% dan 89.43%. Hasil akurasi tertinggi merupakan MobileNet-V3, sehingga arsitektur ini merupakan yang paling efektif untuk melakukan klasifikasi tumor otak.

Kata kunci: Convolutional Neural Network, Deep Learning, EfficientNet-B3, MobileNet-V3, Tumor Otak

ABSTRACT

Brain tumor is a disease that can occur not only in adults, but children can also suffer from brain tumors. This disease is malignant and can affect other tissues, so it is better if brain tumors can be detected early for effective treatment and prevent complications even death. To classify the types of brain tumors more efficiently, a Deep Learning algorithm, namely Convolutional Neural Network (CNN), is utilized. The CNN architecture used in this research are EfficientNetB3 and MobileNetV3. This research uses the Brain Tumor Classification dataset from Kaggle which contains 3264 images of brain tumors categorized into 4 classes, namely glioma tumor, meningioma tumor, no tumor, and pituitary tumor. The aim of this research is to compare the classification results of the CNN architecture used, to obtain the highest accuracy value. This study uses a quantitative approach to classify brain tumors. The training data accuracy results obtained from the EfficientNet-B3 and MobileNet-V3 architectures were 92.53% and 88.03% respectively, while the test data accuracy was 92.53% and 87% respectively. The highest accuracy result is MobileNet-V3, so this architecture is the effective for classifying brain tumors.

Keywords: Convolutional Neural Network, Deep Learning, EfficientNet-B3, MobileNet-V3, Brain Tumor

1 PENDAHULUAN

Otak merupakan bagian sistem saraf pusat yang berfungsi mengatur organ tubuh lainnya [1]. Tumor otak adalah penyakit yang ditandai tumbuhnya sel-sel atau jaringan abnormal di otak yang bersifat kanker (ganas) atau non-kanker (jinak) [2]. Di Indonesia sekitar 300 pasien didiagnosis tumor otak setiap tahunnya, tetapi bukan hanya orang dewasa yang dapat terserang tumor otak, anak-anak pun dapat terserang penyakit tumor otak [3]. Karena penyakit ini bersifat menyebar dan dapat menyerang ke jaringan lain, akan lebih baik untuk mendeteksi dan mengklasifikasi jenis tumor otak sejak dini agar dapat dilakukan pengobatan dan mencegah terjadinya komplikasi bahkan kematian

Citra adalah gambar dua dimensi yang tersusun dari banyak piksel, sedangkan citra digital adalah matriks yang terdiri dari indeks baris dan kolom dengan titik pada citra tersebut dan elemen

matriks menyatakan nilai tingkat derajat keabuan sebagai elemen piksel [4]. Citra digital terbagi menjadi beberapa tipe, yaitu citra biner, citra keabuan (*grayscale*) dan citra warna.

Dalam dunia kesehatan terdapat pendekatan anatomi citra, seperti *Computer Tomography* (CT) *Scan* dan *Magnetic Resonance Imaging* (MRI). CT-Scan biasa digunakan untuk melihat struktur tulang dan tidak sesuai jika digunakan untuk mendeteksi jaringan lunak pada otak. Untuk mendeteksi tumor otak dapat dilakukan pemeriksaan dengan MRI, karena dapat memberikan informasi citra lebih dalam dengan gambaran informasi antar jaringan lunak dan keras yang ada di otak [5]. Dari segmentasi citra dapat memberikan informasi penting bagi dokter untuk mengevaluasi, namun segmentasi secara manual membutuhkan waktu yang lama. Oleh karena itu segmentasi otomatis diperlukan untuk membuat suatu model yang dapat mengklasifikasi dan menganalisis data untuk memberikan hasil akurasi yang baik serta mengatasi permasalahan waktu yang dibutuhkan [6].

Machine Learning adalah cabang kecerdasan buatan atau *Artificial Intelligence* (AI) yang fokus pada algoritma dan model komputer untuk mempelajari pola data, melakukan prediksi, dan pengambilan keputusan [7]. *Deep Learning* merupakan cabang ilmu dari *Machine Learning* yang berfokus pada *Artificial Neural Network* (ANN) atau Jaringan Syaraf Tiruan (JST) yang memanfaatkan banyak lapis atau lebih dari 7 lapis, untuk mempercepat proses pembelajaran [8]. Salah satu algoritma *Deep Learning* yang banyak digunakan untuk menangani masalah analisis dan klasifikasi untuk data citra digital adalah *Convolutional Neural Network* (CNN) [9].

Dalam penelitian ini digunakan dua arsitektur CNN, yaitu *EfficientNet-B3* dan *MobileNet-V3*. *EfficientNet* memprediksi dengan 3 dimensi penskalaan, yaitu kedalaman (*depth*), lebar (*width*) dan resolusi (*resolution*), serta dapat mengurangi ukuran parameter dari *Floating Point Operations Per Second* (FLOPS) [10]. *MobileNet* didesain efisien dengan 2 *hyper-parameters* dan dibuat dengan *depthwise separable convolutions* agar komputasi di *layer* awal berkurang [11].

Penelitian ini menggunakan algoritma *supervised learning*, karena setiap citra MRI pada *dataset* sudah diberi label untuk mengidentifikasi jenis tumor otak. Tujuan dari penelitian ini adalah untuk melakukan klasifikasi tumor otak yang terbagi menjadi empat kelas dengan dua arsitektur CNN yaitu, *EfficientNet-B3* dan *MobileNet-V3*, lalu membandingkan hasil klasifikasi memakai *epoch* atau banyak pelatihan 35, 50 dan 100. Hasil dari klasifikasi ini diharapkan dapat membantu tenaga medis dalam mendeteksi dan mengidentifikasi jenis tumor otak pasien secara efisien.

2 TINJAUAN LITERATUR

Penelitian mengenai klasifikasi kualitas tumor otak pada citra MRI sudah banyak dilakukan dengan menggunakan penerapan algoritma CNN. Pada penelitian yang dilakukan oleh Monikka Nur Winnarto, dkk pada tahun 2022 menggunakan arsitektur *MobileNet-V2*. Klasifikasi citra tumor otak dilakukan ke dalam 4 kelas, yaitu glioma, meningioma, tanpa tumor, dan pituitary memperoleh nilai akurasi sebesar 88.64% [9]. Dari penelitian tersebut didapatkan kesimpulan bahwa arsitektur *MobileNet-V2* yang dilakukan, mampu mengklasifikasikan jenis tumor otak dan efisien dalam memori dan kompleksitas.

Penelitian yang dilakukan oleh J. Seetha dan S. Selvakumar Raja pada tahun 2018, klasifikasi tumor otak dilakukan ke dalam 2 kelas, yaitu tumor dan non-tumor dengan *dataset* dari repositori publik, yaitu *Radiopaedia* dan *Brain Tumor Image Segmentation Benchmark* (BRATS) dengan menggunakan fitur ekstraksi mendapat nilai akurasi sebesar 97.5% [12].

Penelitian klasifikasi jenis tumor otak oleh Anti Nada Nafisa, dkk pada tahun 2023 menggunakan arsitektur model *MobileNet-V2* pada data testing mendapatkan akurasi sebesar 78% dan data validasi sebesar 83% [13]. Penelitian yang dilakukan menggunakan citra dengan ukuran piksel yang sudah di *resize*, yaitu 128 x 128 piksel. Kemudian data dibagi menjadi 3 kelas, yaitu data

train, data *test*, dan data validasi. Dari hasil penelitian disimpulkan MobileNet-V2 mampu melakukan klasifikasi tumor otak jenis pituitary dengan sangat baik, tetapi model belum bisa total mengklasifikasikan glioma dan meningioma.


Penelitian yang dilakukan oleh Widi Hastomo, dkk pada tahun 2021 menggunakan arsitektur model MobileNet-V2. Dataset yang digunakan diklasifikasi ke dalam 4 kelas dengan jumlah data yang berbeda. Pelatihan dan pengujian yang dilakukan menggunakan seluruh *dataset* sehingga hasil *training* mendapat akurasi sebesar 97% dan testing 94% [14]. Nilai akurasi yang diperoleh sangat baik, akan tetapi penggunaan dataset yang sama untuk melatih dan menguji model dapat memungkinkan terjadinya *overfitting*. *Dataset* yang digunakan lebih baik dilakukan pembagian terlebih dahulu untuk menghindari terjadinya *overfitting*.

Dari analisis yang telah dilakukan peneliti, terkait dengan penelitian klasifikasi tumor otak dengan arsitektur CNN. Hanya sedikit penelitian yang menggunakan arsitektur EfficientNet, dan lebih banyak penggunaan dalam MobileNet-V2. Namun penggunaan arsitektur selain MobileNet-V2 dapat memberikan peluang dalam peningkatan hasil akurasi dalam melakukan klasifikasi tumor otak. Penelitian ini berfokus pada perbandingan antara dua arsitektur CNN, yaitu MobileNet versi 3 dan EfficientNet yang berkala 3. MobileNet-V3 merupakan lanjutan dari versi 2 yang diharapkan dapat memberikan efisiensi dan akurasi yang lebih baik, sedangkan EfficientNet-B3 digunakan untuk membandingkan hasil akurasi yang diperoleh nantinya.

3 METODE PENELITIAN


Penelitian ini menggunakan bahasa pemrograman Python dengan beberapa *library* seperti Numpy, Pandas, Matplotlib, TensorFlow, Keras dan lain-lain, program dijalankan menggunakan *Graphics Processing Unit* (GPU) pada Google Colab dengan tipe T4 GPU. Penelitian ini menggunakan pendekatan secara kuantitatif untuk mengklasifikasikan tumor otak. Karena data dalam penelitian kuantitatif dapat diperoleh dari mengubah data kualitatif seperti gambar menjadi data kuantitatif [15].

Flowchart dari metode penelitian dengan metode CNN untuk klasifikasi citra tumor otak dapat dilihat pada gambar 1 [16].




Gambar 1 *Flowchart* Metode Penelitian dengan CNN

Penelitian ini menggunakan *dataset Brain Tumor Classification* dari Kaggle (<https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>) dengan tipe data citra format jpg. *Dataset* dibagi menjadi data latih dan data uji dengan perbandingan 8:2, sama dengan 80% data latih dan 20% data uji. Jumlah data yang digunakan sebesar 2870 citra untuk *training* dan 394 citra untuk *testing*. Data kemudian dibagi menjadi 3 kategori, yaitu data latih, data validasi, dan data uji. *Dataset* ini terdiri dari 4 jenis tumor otak, yaitu glioma, meningioma, tanpa tumor dan pituitary. Contoh dari empat jenis tumor otak dapat dilihat pada gambar 2.



Gambar 2 Contoh *Dataset* pada Empat Jenis Tumor Otak

Data citra yang digunakan memiliki ukuran piksel yang bervariasi yaitu 236 x 236 piksel dan 512 x 512 piksel, data citra tersebut kemudian akan dimasukkan ke dalam metode CNN. Flowchart proses dari metode CNN dapat dilihat pada gambar 3.



Gambar 3 Flowchart Proses Metode CNN

Data citra yang berbeda ukuran piksel selanjutnya akan diproses terlebih dahulu dengan *resizing* dan *rescaling* citra. *Resizing* adalah proses merubah ukuran citra menjadi lebih besar atau lebih kecil, sedangkan *rescaling* adalah proses merubah nilai piksel agar memiliki nilai antara nol dan satu yang dapat dilakukan dengan membagi nilai piksel dengan besaran 255 [17]. Dalam penelitian ini data citra diubah ukurannya menjadi 224 x 224 piksel dan dinormalisasi dengan cara membagi nilai piksel dengan besaran 255.

Peneliti kemudian membuat pemodelan dari dua arsitektur CNN, yaitu EfficientNet-B3 dan MobileNet-V3 dengan menggunakan data latih. Setelah model selesai dirancang, selanjutnya klasifikasi dengan algoritma *Deep Learning* dilakukan dengan data validasi dan juga data uji menggunakan model yang sudah dibuat. Hasil dari klasifikasi yang dilakukan ditampilkan dalam bentuk kurva dan menggunakan metode evaluasi. Dalam pelatihan model digunakan *callback* dengan library *Model Checkpoint* untuk menyimpan bobot model dengan akurasi validasi tertinggi, dan *Early Stopping* untuk menghentikan pelatihan ketika tidak ada peningkatan dalam nilai loss validasi selama 5 epoch berturut-turut [18].

Evaluasi dari model yang telah dibangun dengan proses *training* adalah hal yang penting. Tujuan dari evaluasi adalah mengukur performa atau kinerja model apakah mampu melakukan klasifikasi dengan baik atau tidak. Metode evaluasi dalam penelitian ini adalah Confusion Matrix dan laporan klasifikasi yang terdiri dari *precision*, *recall*, *f1-score*, dan *support*.

Confusion Matrix adalah tabel perbandingan hasil klasifikasi yang diprediksi dengan hasil klasifikasi yang sebenarnya [19]. *Confusion matriks* yang digunakan dalam penelitian ini memiliki dimensi 4 × 4 seperti pada Gambar 4.

		Prediksi			
Aktual	Kelas	Glioma	Meningioma	No Tumor	Pituitary
	Glioma	C ₁	C ₂	C ₃	C ₄
	Meningioma	C ₅	C ₆	C ₇	C ₈
	No Tumor	C ₉	C ₁₀	C ₁₁	C ₁₂
	Pituitary	C ₁₃	C ₁₄	C ₁₅	C ₁₆

Gambar 4 Confusion Matrix

Ada 4 nilai untuk menghitung nilai akurasi dan laporan klasifikasi yang terdiri dari presisi, *recall*, dan *f1-score*, yaitu

- 1) *True Positive* (TP) : jumlah sampel data yang diklasifikasikan positif
- 2) *True Negative* (TN) : jumlah sampel data diklasifikasikan negatif
- 3) *False Positive* (FP) : jumlah sampel data diklasifikasikan positif, tetapi sebenarnya negatif
- 4) *False Negative* (FN) : jumlah sampel data diklasifikasikan negatif tetapi sebenarnya Positif

Berdasarkan nilai yang didapat dari *Confusion Matriks* dapat dihasilkan laporan klasifikasi sebagai berikut.

1) Akurasi

Akurasi adalah metrik untuk evaluasi model klasifikasi, yang merupakan perhitungan pecahan jumlah prediksi yang benar dengan total prediksi yang ada. Persamaan akurasi dapat dilihat pada persamaan 1.

$$Accuracy = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah semua prediksi}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

2) Presisi

Presisi adalah informasi data yang diambil salah atau tidak tepat dan menunjukkan tingkat ketepatan dalam klasifikasi [20]. Persamaan presisi dapat dilihat pada persamaan 2.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

3) Recall

Recall adalah pengukuran proporsi positif yang benar diidentifikasi dan menunjukkan berapa persen data positif diklasifikasikan benar oleh sistem. Persamaan recall dapat dilihat pada persamaan 3.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

4) F1-score atau F-measure

F1-score adalah gabungan dari metrik presisi dan recall yang merupakan “harmonisasi” dari kedua metrik tersebut karena mengambil rata-rata dari kedua metrik. Persamaan recall dapat dilihat pada persamaan 4.

$$F\text{-measure} = \frac{2 \times precision \times recall}{precision + recall} \quad (4)$$


4 HASIL DAN PEMBAHASAN

Dataset yang digunakan adalah dataset citra MRI Tumor Otak dari Kaggle. Dataset tumor otak ini memiliki data 3264 citra tumor otak. Dataset ini terdiri dari 4 jenis tumor otak, yaitu glioma, meningioma, tanpa tumor dan pituitary. Jumlah citra dari setiap kelas dapat dilihat pada tabel 1.

Tabel 1 Jumlah Citra Setiap Kelas

No	Kelas	Jumlah Citra
1	Glioma Tumor	926 citra
2	Meningioma Tumor	937 citra
3	No Tumor	500 citra
4	Pituitary Tumor	901 citra

Dataset kemudian dilakukan *preprocessing*, yaitu di *resize* dan *rescale*. Contoh hasil dari proses *preprocessing data* dapat dilihat pada gambar 5.



Gambar 5 Contoh Hasil *Preprocessing Data*

Penelitian ini menggunakan dua jenis arsitektur yaitu, EfficientNet-B3 dan MobileNet-V3 untuk mengklasifikasikan jenis tumor otak. Pengujian dilakukan dengan membedakan jumlah *epoch* sebanyak 35, 50 dan 100 untuk membandingkan hasil klasifikasi 4 jenis tumor otak. Hasil pelatihan model dengan data *training* dari arsitektur EfficientNet-B3 dapat dilihat pada tabel 2.

Tabel 2 Hasil Pelatihan Model Arsitektur EfficientNet-B3


Epoch	Akurasi	Loss	Val_Akurasi	Val_Loss	Time
35	0.8095	0.5184	0.7778	0.5695	267ms/step
50	0.8348	0.4527	0.8161	0.5002	170ms/step
100	0.8923	0.3019	0.8467	0.4084	160ms/step

Hasil pelatihan model dari arsitektur MobileNet-V3 dapat dilihat pada tabel 3.


Tabel 3 Hasil Pelatihan Model Arsitektur MobileNet-V3

Epoch	Akurasi	Loss	Val_Akurasi	Val_Loss	Time
35	0.8071	0.5137	0.8008	0.5258	174ms/step
50	0.8439	0.4234	0.8314	0.4514	138ms/step
100	0.9062	0.2582	0.8621	0.3689	153ms/step


Grafik akurasi dan *loss train* dan validasi untuk jumlah pelatihan atau *epoch* sebesar 100 pada EfficientNet-B3 dapat dilihat pada gambar 6 dan 7, dan grafik untuk MobileNet-V3 dapat dilihat pada gambar 8 dan 9.




Gambar 6 Grafik Loss Train dan Validasi pada EfficientNet-B3



Gambar 7 Grafik Akurasi Train dan Validasi pada EfficientNet-B3



Gambar 8 Grafik *Loss Train* dan *Validasi* pada *MobileNet-V3*



Gambar 9 Grafik *Akurasi Train* dan *Validasi* pada *MobileNet-V3*


Nilai akurasi yang dihasilkan merupakan nilai prediksi model ketika dapat memprediksi dengan tepat, sedangkan nilai *loss* adalah nilai prediksi model ketika memprediksi dengan tidak tepat. Nilai *train* dan *validasi* pada grafik akurasi menggambarkan model yang digunakan jika mendekati angka satu maka semakin baik hasilnya (semakin tinggi semakin baik). Sedangkan nilai *train* dan *validasi* pada grafik *loss* menggambarkan sebaliknya, yaitu mendekati nol semakin baik (semakin rendah semakin baik). Dari hasil pelatihan model data *training*, didapatkan nilai akurasi terbesar dan nilai *loss* terkecil untuk *EfficientNet-B3* dan *MobileNet-V3* ada pada jumlah *epoch* 100. Nilai akurasi yang didapat *EfficientNet-B3* sebesar 0.8803 atau 88.03% dan *MobileNet-V3* sebesar 0.9253 atau 92.53%. Sedangkan nilai *loss* yang didapat 0.3169 untuk *EfficientNet-B3* dan 0.2265 untuk *MobileNet-V3*.

Hasil akurasi setiap epoch untuk data ujinya ditampilkan pada tabel 4.

Tabel 4 Hasil Akurasi Model dengan Data Uji


Arsitektur	Epoch	Akurasi
EfficientNet-B3	35	0.8208
	50	0.8315
	100	0.8744
MobileNet-V3	35	0.8453
	50	0.8576
	100	0.8943

Hasil metode evaluasi dari pengujian model menggunakan data uji diberikan dalam *Confusion Matrix* dan laporan klasifikasi. Hasil *Confusion Matrix* dengan *epoch* 100 pada arsitektur EfficientNet-B3 dan MobileNet-V3 dapat dilihat pada gambar 10 dan 11.



Gambar 10 Confusion Matrix EfficientNet-B3

Kelas pada *confusion matrix* diatas yaitu, kelas 0 untuk glioma tumor, kelas 1 untuk meningioma tumor, kelas 2 untuk no tumor dan kelas 3 untuk pituitary tumor. Laporan klasifikasi untuk evaluasi pengujian model menggunakan data uji akan ditampilkan pada tabel 3.



Gambar 11 Confusion Matrix MobileNet-V3

Tabel 5 Laporan Klasifikasi

Kelas	Arsitektur	Precision	Recall	F1-Score	Support
Glioma Tumor	EfficientNet-B3	0.89	0.83	0.86	185
Meningioma Tumor	EfficientNet-B3	0.83	0.81	0.82	188
No Tumor	EfficientNet-B3	0.89	0.90	0.90	91
Pituitary Tumor	EfficientNet-B3	0.90	0.96	0.93	189
Accuracy	EfficientNet-B3			0.87	653
Glioma Tumor	MobileNet-V3	0.92	0.83	0.87	185
Meningioma Tumor	MobileNet-V3	0.84	0.87	0.85	188
No Tumor	MobileNet-V3	0.89	0.92	0.91	91
Pituitary Tumor	MobileNet-V3	0.93	0.97	0.95	189
Accuracy	MobileNet-V3			0.89	653

Dari hasil laporan klasifikasi diatas, nilai akurasi tertinggi adalah 0.89 atau 89% untuk arsitektur MobileNet-V3. Sedangkan arsitektur EfficientNet-B3 mendapat nilai akurasi sebesar 0.87 atau 87% Penelitian ini memiliki keunikan membandingkan kinerja dari dua arsitektur model yang berbeda, yaitu EfficientNet-B3 dan MobileNet-V3 dengan jumlah pelatihan atau *epoch* yang berbeda. Kelebihan dari penelitian ini adalah tidak hanya memberikan hasil dari akurasi, tetapi juga hasil dari *precision*, *recall* dan *f1-score*, dan terdapat informasi yang jelas terkait dengan jumlah sampel (*support*).

5 KESIMPULAN

Dari penelitian ini dapat disimpulkan bahwa jumlah pelatihan atau *epoch* mempengaruhi hasil akurasi penelitian. Dari hasil penelitian dapat disimpulkan kinerja arsitektur MobileNet-V3 memberikan hasil akurasi data latih dan data uji terbaik sebesar 90.62% dan 89.43% dengan jumlah epoch 100. Tetapi arsitektur EfficientNet-B3 juga memberikan hasil akurasi data latih dan data uji yang baik sebesar 89.23% dan 87.44%. Dari hasil akurasi yang diperoleh dengan arsitektur model CNN untuk memprediksi tumor otak pada citra MRI, MobileNet-V3 dapat digunakan untuk melakukan klasifikasi karena memberikan kinerja yang baik. Tetapi untuk hasil akurasi yang lebih maksimal dapat menggunakan arsitektur yang berbeda atau menggunakan versi dan skala arsitektur yang berbeda dari penelitian ini.

DAFTAR PUSTAKA

- [1] K. Amelia, R. Magladena and S. Saidah, "Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN Dengan Arsitektur Alexnet," eProceedings of Engineering, vol. 9, 2023.
- [2] K. Deeksha, M. Deeksha, A. V. Girish, A. S. Bhat and H. Lakshmi, "Classification of Brain Tumor and its types using Convolutional Neural Network," in 2020 IEEE International Conference for Innovation in Technology (INOCON), 2020, pp. 1--6.
- [3] A. S. Febrianti, T. A. Sardjono and A. F. Babgei, "Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine," Jurnal Teknik ITS (SINTA: 4, IF: 1.1815), vol. 9, pp. A118--A123, 2020.

- [4] S. R. Dewi, "Deep Learning Object Detection Pada Video Menggunakan *Tensorflow* Dan *Convolutional Neural Network*," 2018.
- [5] R. A. Ramadhani, B. W. Pangestu and R. Purbaningtyas, "Klasifikasi Tumor Otak Menggunakan *Convolutional Neural Network* dengan Arsitektur *EfficientNet-B3*," *JUST IT: Jurnal Sistem Informasi, Teknologi Informasi dan Komputer*, vol. 12, pp. 55--59, 2022.
- [6] I. Suta, R. S. Hartati and Y. Divayana, "Diagnosa tumor otak berdasarkan citra MRI (*Magnetic Resonance Imaging*)," *Maj. Ilm. Teknol. Elektro*, vol. 18, pp. 149--154, 2019.
- [7] I. M. Faiza and W. Andriani, "Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir," *Jurnal Minfo Polgan*, vol. 11, pp. 59-63, 2022.
- [8] J. Pujoseno, "*Implementasi Deep Learning* Menggunakan *Convolutional Neural Network* Untuk Klasifikasi Alat Tulis," 2018.
- [9] M. N. Winnarto, M. Mailasari and A. Purnamawati, "Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur *MobileNet V2*," *Jurnal SIMETRIS*, vol. 13, pp. 1--12, 2022.
- [10] W. R. PERDANI, R. MAGDALENA and N. K. C. PRATIWI, "Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur *EfficientNet*," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, p. 322, 2022.
- [11] J. Feriawan and D. Swanjaya, "Perbandingan Arsitektur *Visual Geometry Group* dan *MobileNet* Pada Pengenalan Jenis Kayu," *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 4, pp. 185--190, 2020.
- [12] J. Seetha and S. S. Raja, "Brain tumor classification using *convolutional neural networks*," *Biomedical & Pharmacology Journal*, vol. 11, p. 1457, 2018.
- [13] F. A. A. Harahap, A. N. Nafisa, E. N. D. B. Purba and N. A. Putri, "Implementasi Algoritma *Convolutional Neural Network* Arsitektur Model *MobileNetV2* dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma," *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTika)*, vol. 5, pp. 53--61, 2023.
- [14] W. Hastomo, "Convolution Neural Network Arsitektur *MobileNet-V2* Untuk Mendeteksi Tumor Otak," in *Prosiding Seminar SeNTIK*, vol. 5, 2021, pp. 17--21.
- [15] M. Ramdhan, Metode penelitian, Cipta Media Nusantara, 2021.
- [16] I. Fauzi and A. Moenir, "Klasifikasi Spesies Tanaman *Magnolia* Menggunakan Metode *Convolutional Neural Networks*," *Journal of Artificial Intelligence and Innovative Applications*, vol. 2, pp. 235-239, 2021.
- [17] S. F. Handono, F. T. Anggraeny and B. Rahmat, "Implementasi *Convolutional Neural Network (CNN)* untuk Deteksi Retinopati Diabetik," *Jurnal Informatika dan Sistem Informasi*, vol. 1, pp. 669--678, 2020.
- [18] A. I. Hanifah and A. Hermawan, "Klasifikasi Kematangan Pisang Menggunakan Metode *Convolutional Neural Network*," *Komputika: Jurnal Sistem Komputer*, vol. 12, pp. 49--56, 2023.
- [19] M. I. Fikri, T. S. Sabrila and Y. Azhar, "Perbandingan metode *naïve bayes* dan *support vector machine* pada analisis sentimen twitter," *SMATIKA Jurnal: STIKI Informatika Jurnal*, vol. 10, pp. 71-76, 2020.
- [20] K. Nugroho and S. Murdowo, "Klasifikasi Jenis Hewan Pada Kebun Binatang Dengan Menggunakan Metode *Deep Neural Network*," *Jurnal Ilmiah Infokam*, vol. 18, pp. 46-51, 2022.