

Deteksi Tumor Otak Melalui Gambar MRI Berdasarkan Vision Transformers dengan Tensorflow dan Keras

Oki Akbar¹, Ema Utami², and Dhani Ariatmanto³

Universitas Amikom Yogyakarta, Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta, Indonesia, 55281

e-mail: ¹oki@student.amikom.ac.id, ²ema.u@amikom.ac.id, ³dhaniari@amikom.ac.id

Submitted Date: June 06th, 2023
Revised Date: August 22nd, 2023

Reviewed Date: August 11th, 2023
Accepted Date: September 01st, 2023

Abstract

Brain tumor disease is a serious and complex health problem worldwide. Early and accurate detection of brain tumors has a major impact on patient care and prognosis. Magnetic Resonance Imaging (MRI) has become one of the main diagnostic tools in detecting brain tumors, manual interpretation of MRI images requires high clinical expertise and requires a long time. In recent years, advances in deep learning techniques and image processing have opened up new opportunities in the detection of brain tumors via MRI images. Deep learning techniques, especially the use of Vision Transformers (ViTs) models, have been successful in various complex pattern recognition tasks in images. The Vision Transformers model was chosen due to the performance improvements shown in many image recognition tasks, outperforming convolutional neural networks (CNN) based methods. Tensorflow and Keras are used as frameworks for development and training models, which have been proven effective and efficient in various previous studies. This study focuses on the performance of the Vision Transformer (ViT) in detecting brain tumors through two Magnetic Resonance Imaging (MRI) image datasets, with different numbers of datasets, as well as the maximum accuracy value that can be achieved from the ViT architecture. From several experimental parameters on ViT, the number of datasets and iterations, the results obtained from the first dataset with 253 image data obtained an accuracy value of 88%, and in the second study by combining the two datasets, with 3.123 data images obtained an accuracy of 97.9%.

Keywords: Brain tumor; Vision Transformer; Tensorflow; Keras

Abstrak

Penyakit tumor otak merupakan salah satu masalah kesehatan yang serius dan kompleks di seluruh dunia. Deteksi dini dan akurat dari tumor otak memiliki dampak besar pada perawatan dan prognosis pasien. Magnetic Resonance Imaging (MRI) telah menjadi salah satu alat diagnostik utama dalam deteksi tumor otak, interpretasi manual gambar MRI memerlukan keahlian klinis yang tinggi dan memerlukan waktu yang lama. Dalam beberapa tahun terakhir, kemajuan dalam teknik deep learning dan pengolahan citra telah membuka peluang baru dalam deteksi tumor otak melalui gambar MRI. Teknik deep learning, khususnya penggunaan model Vision Transformers (ViTs), telah berhasil dalam berbagai tugas pengenalan pola kompleks dalam citra. Model Vision Transformers dipilih karena peningkatan kinerja yang ditunjukkan dalam banyak tugas pengenalan gambar, mengungguli metode berbasis convolutional neural network (CNN). Tensorflow dan Keras digunakan sebagai framework untuk pengembangan dan pelatihan model, yang telah terbukti efektif dan efisien dalam berbagai penelitian sebelumnya. Penelitian ini berfokus pada kinerja Vision Transformer (ViT) dalam mendeteksi tumor otak melalui dua buah dataset gambar Magnetic Resonance Imaging (MRI), dengan jumlah dataset yang berbeda, Serta Nilai accuracy maksimal yang bisa dicapai dari arsitektur ViT. Dari beberapa eksperimen parameter pada ViT, jumlah dataset dan iterasi, Hasil yang diperoleh dari Dataset pertama dengan data gambar sebanyak 253 didapat nilai akurasi sebesar 88%,



dan pada penelitian kedua dengan menggabungkan dua dataset, data gambar sebanyak 3.123 diperoleh accuracy sebanyak 97,9%.

Keywords: Tumor Otak; Vision Transformer; Tensorflow; Keras

1. Pendahuluan

Tumor otak adalah kumpulan sel-sel abnormal yang tumbuh secara tidak wajar dan tidak terkendali di dalam otak (Ghozali, 2021). Tumor otak dapat menjadi penyakit yang sangat mematikan, dengan glioma menjadi salah satu jenis tumor otak yang paling umum (Suta Dkk 2019). Gejala tumor otak dapat bervariasi tergantung pada lokasi dan ukuran tumor. Beberapa gejala umum yang dapat muncul termasuk sakit kepala, mual dan muntah, kejang, perubahan perilaku, gangguan penglihatan, dan kelemahan pada satu sisi tubuh (Kristian Dkk 2021). Citra digital melalui Magnetic Resonance Imaging (MRI) digunakan sebagai metode untuk membantu dokter dalam menganalisis dan mengklasifikasikan jenis tumor otak (Suta Dkk 2019). Citra MRI dapat memberikan informasi yang akurat tentang pemisahan jaringan tumor otak (Wulansari & Rahman, 2022). Namun, klasifikasi secara manual membutuhkan waktu yang lama dan memiliki risiko kesalahan yang tinggi, sehingga diperlukan cara otomatis dan akurat untuk melakukan klasifikasi citra MRI (Suta Dkk 2019).

Beberapa penelitian terkait prediksi, identifikasi ataupun klasifikasi terhadap tumor otak telah banyak dilakukan dengan berbagai metode dan hasil yang beragam. Seperti penelitian Klasifikasi Tumor Otak pada MRI Menggunakan SVM Dari hasil pengujian klasifikasi didapatkan tingkat akurasi 0.76 (Febrianti Dkk 2020), Selanjutnya penelitian menggunakan arsitektur CNN oleh (Febrianti Dkk 2020), diperoleh hasil bahwa CNN mampu dalam mengenali jenis tumor otak dengan tingkat keberhasilan rata-rata di atas 90%.

Kemudian penelitian Menggunakan UNet-VGG16 dapat mengenali area tumor otak dengan rata-rata nilai CCR sekitar 95,69% (Pravitasari Dkk 2020), selanjutnya penelitian Menggunakan Ekstraksi Fitur HOG & SVM mendapatkan tingkat akurasi sebesar 91% (Adilah Dkk 2022).

Penelitian Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur Mobilenet V2 (Winnarto Dkk 2022) mampu melakukan klasifikasi jenis tumor otak dengan hasil akurasi sebesar 88.64%,

Selanjutnya Penelitian tumor otak Menggunakan Metode Deep Belief Network (DBN) menghasilkan nilai akurasi sebesar 95% (Fattah Dkk 2021).

Vision Transformer merupakan salah satu model deep learning arsitektur jaringan saraf berbasis transformator, yang awalnya dikembangkan untuk tugas pemrosesan Natural Language, tetapi diadaptasi untuk Computer Vision. ViT menghilangkan penggunaan konvolusi yang dominan dalam model CNN dan menggantinya dengan lapisan self-attention dan lapisan feed-forward dalam blok-blok Transformer (Houlsby 2023)(Dosovitskiy 2021).

TensorFlow adalah sebuah perangkat lunak yang dikembangkan oleh Google untuk melakukan penelitian dan pengembangan kecerdasan buatan. TensorFlow mendukung penggunaan jaringan saraf konvolusional (CNN). Tensor adalah unit data pusat dalam TensorFlow dan terdiri dari sekumpulan tipe data primitif yang dibentuk menjadi array dari dimensi apa pun (Tiku Dkk 2022).

Keras juga merupakan API untuk TensorFlow yang sangat populer di komunitas deep learning, Keras dirancang khusus untuk mempercepat eksperimen yang berhubungan dengan deep learning (Chicho & Sallow, 2021).

TensorFlow dan Keras sering digunakan bersama-sama dalam pengembangan model deep learning. TensorFlow adalah library open-source yang digunakan untuk mengembangkan model machine learning, sedangkan Keras adalah API yang memudahkan pengguna untuk memperkenalkan, melatih, dan menganalisis jaringan saraf (Zhao, 2023). Keras juga digunakan dalam berbagai aplikasi, seperti deteksi masker, penerjemah bahasa isyarat, dan pengenalan gambar (Dao Dkk 2022; Alfikri Dkk 2022; Chicho & Sallow, 2021).

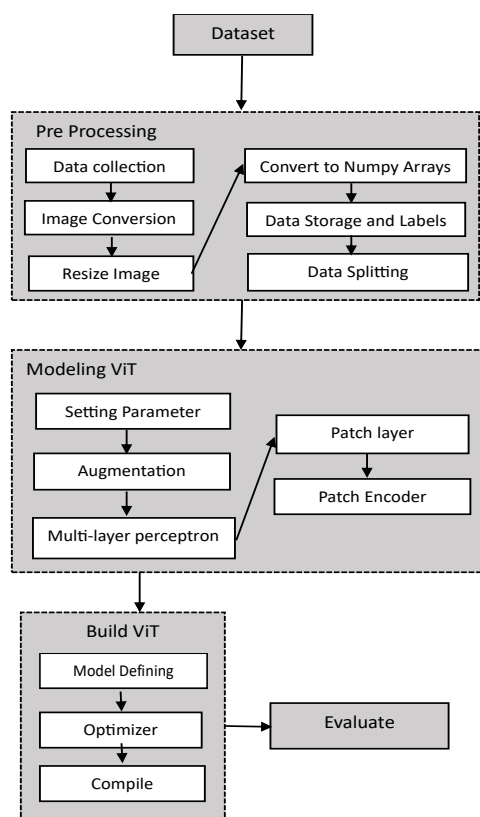
Secara keseluruhan, TensorFlow dan Keras adalah perangkat lunak yang sering digunakan dalam pengembangan model deep learning. TensorFlow adalah library yang digunakan untuk mengembangkan model machine learning, sedangkan Keras adalah API yang memudahkan

pengguna untuk memperkenalkan, melatih, dan menganalisis jaringan saraf. Keduanya sering digunakan bersama-sama dalam pengembangan model deep learning untuk berbagai aplikasi.

Pada penelitian ini, Arsitektur Vision Transformer diusulkan untuk mendeteksi tumor otak pada gambar MRI, Penelitian ini bertujuan untuk menggabungkan keunggulan Vision Transformers, yang mampu menangkap informasi spasial dalam citra, dengan kemampuan TensorFlow dan Keras dalam melatih dan mengoptimasi model neural network. Diharapkan dengan menggunakan Vision Transformers dan TensorFlow-Keras, dapat menghasilkan model deteksi tumor otak yang memiliki tingkat akurasi yang tinggi. Penelitian ini berfokus pada kinerja Vision Transformer (ViT) dalam mendeteksi tumor otak melalui dua buah dataset gambar Magnetic Resonance Imaging (MRI), dengan jumlah dataset yang berbeda, Serta Nilai accuracy maksimal yang bisa dicapai dari arsitektur ViT.

2. Metode Penelitian


Berikut alur penelitian yang dilakukan pada penelitian ini.




Gambar 1. Alur Penelitian

2.1. Dataset

Penelitian ini menggunakan dua dataset untuk ujicoba, Dataset diambil dari Kaggle, yaitu MRI Images for Brain Tumor Detection (dataset 1), dengan jumlah data gambar 253 dan Dataset Brain Tumor Classification (dataset 2) dengan jumlah gambar 2.870, Total gambar dataset keseluruhan sebanyak 3.123, berikut sampel gambar secara acak.



Gambar 2. Brain Tumor MRI terdeteksi Yes



Gambar 3. Brain Tumor MRI terdeteksi No

2.2 Pre-Processing

Tahapan Pre-Processing yang dilakukan pada penelitian ini:

a. Data Collection

Mengakses file-file gambar diambil dari direktori yang tersimpan di google drive, mengambil daftar nama file dari direktori MRI Image, direktori No (tidak terdeteksi tumor) dan Yes (terdeteksi tumor).

b. Image Conversion

Gambar yang awalnya dibaca sebagai array menggunakan library OpenCV

diubah menjadi objek gambar PIL (Python Imaging Library).

c. Resize Image

Ukuran Gambar pada dataset berbeda beda, sehingga perlu dilakukan resize image agar semua gambar memiliki ukuran yang sama, diubah menjadi 100x100 pixel.

d. Convert to Numpy Arrays

Setelah Resize image selanjutnya Objek gambar PIL diubah menjadi array numpy, Numpy merupakan perpustakaan Python yang digunakan untuk manipulasi array dan matriks yang besar dan multi-dimensi.

e. Data Storage and Labels

Kemudian Gambar yang telah diubah ukurannya dan label yang sesuai ditambahkan ke list yang akan digunakan untuk melatih model.

f. Data Splitting

Dataset gambar dan label dipisah menjadi subset train dan test, Data Train sebanyak 20% dan Test 80%.

2.3 Modelling ViT

Tahapan yang dilakukan pada Modeling Vision Transformer yaitu:

a. Setting Parameter

Mengatur parameter pada arsitektur Vision Transformer, seperti learning rate, weight decay, batch size, batch size, transformer layer, dan lain-lain.

b. Augmentation

Augmentation adalah adalah proses pembuatan sampel pelatihan buatan dengan cara yang realistis untuk memperbanyak data pelatihan, dan juga meningkatkan kinerja model saat digunakan pada data yang belum pernah dilihat sebelumnya (Goodfellow 2016). Pada penelitian ini mengatur augmentation seperti Normalization, Resizing, Randomflip, Random Rotation dan Random Zoom.

c. Multi-layer Perceptron

Merupakan bagian dari arsitektur Vision Transformer. Fungsi ini digunakan untuk membangun lapisan-lapisan MLP (Multi-Layer Perceptron) dalam model.


d. Patch Layer

Digunakan untuk mengambil patch-patch dari gambar sebagai langkah pertama dalam

pemrosesan gambar pada model Vision Transformer.

e. Patch Encoder

Digunakan untuk mengkodekan dan memproyeksikan patch-patch gambar dalam model Vision Transformer.



Gambar 4. Hasil proses Modelling ViT pada gambar MRI Tumor Otak

Gambar di atas merupakan Model overview, dari proses modelling ViT yang dilakukan dalam penelitian ini, Membagi gambar menjadi tambalan tambalan (patch), dengan spesifikasi:

Image size: 80 X 80

Patch size: 20 X 20

Patches per image: 16

Elements per patch: 1200

2.4 Build ViT

Membangun model Vision Transformer (ViT) untuk tugas klasifikasi, pada penelitian ini tahapan yang dilakukan:

a. Model Defining

Pada tahap ini mendefinisikan struktur model Vision Transformer:

- 1) Memulai dengan membuat layer input dengan shape (100, 100, 3) yang

merepresentasikan gambar berwarna 100x100 pixel.

- 2) Selanjutnya, data augmentasi diterapkan pada input, diikuti dengan proses membagi gambar menjadi patch menggunakan fungsi Patches(patch_size).
- 3) Kemudian, patch gambar diubah ke dalam bentuk yang dapat diterima oleh blok Transformer melalui proses encoding.
- 4) Setelah itu dibuatlah blok Transformer, yang terdiri dari beberapa layer normalization, MultiHeadAttention, dan MLP. MultiHeadAttention memungkinkan model untuk lebih fokus pada fitur-fitur tertentu dalam data, sedangkan MLP membantu mempelajari hubungan non-linear antara fitur.
- 5) Proses ini dilakukan sejumlah transformer_layers kali, dan setiap iterasi menghasilkan output yang ditambahkan ke input sebelumnya (skip connection) untuk membantu mengurangi hilangnya informasi selama proses ini.
- 6) Setelah blok transformer, ada layer normalisasi lagi, dan representasi datanya diubah menjadi bentuk satu dimensi (flatten), diikuti oleh lapisan dropout.
- 7) Setelah itu, ada satu set lapisan MLP lagi, yang menghasilkan fitur akhir yang digunakan untuk klasifikasi.
- 8) Lapisan Dense terakhir memiliki jumlah unit yang sama dengan jumlah kelas target, dan menghasilkan output logit, yang kemudian akan diubah menjadi probabilitas dengan fungsi softmax (biasanya dilakukan dalam loss function, seperti SparseCategoricalCrossentropy(from_logits=True)).

b. Optimizer

Optimizer didefinisikan sebagai algoritma atau metode yang digunakan untuk menyesuaikan parameter model guna meminimalkan fungsi kerugian (Goodfellow 2016).

Beberapa algoritma optimizer yaitu Stochastic Gradient Descent (SGD), SGD mengambil sampel acak dari data pelatihan di setiap langkah dan menghitung gradien dari sampel itu saja. RMSprop adalah perbaikan dari SGD yang mengubah laju pembelajaran adaptif untuk setiap parameter dalam model. Selanjutnya optimezer

Adam, singkatan dari "Adaptive Moment Estimation", menggabungkan keuntungan dari dua metode sebelumnya, RMSprop dan momentum. Adam mempertahankan rata-rata bergerak eksponensial dari gradien masa lalu, mirip dengan momentum dan skala gradien secara invers dengan akar kuadrat rata-rata bergerak eksponensial dari gradien kuadrat masa lalu (Chollet 2017).

Pada penelitian ini menggunakan Optimizer adamW, AdamW adalah variasi dari optimizer Adam, Versi "W" dari Adam merupakan peningkatan dari Adam dengan cara memperkenalkan pemisahan eksplisit antara pembaharuan adaptif dari setiap parameter dan penurunan bobot (weight decay), yang diusulkan oleh (Loshchilov 2017)

3. Hasil dan Pembahasan

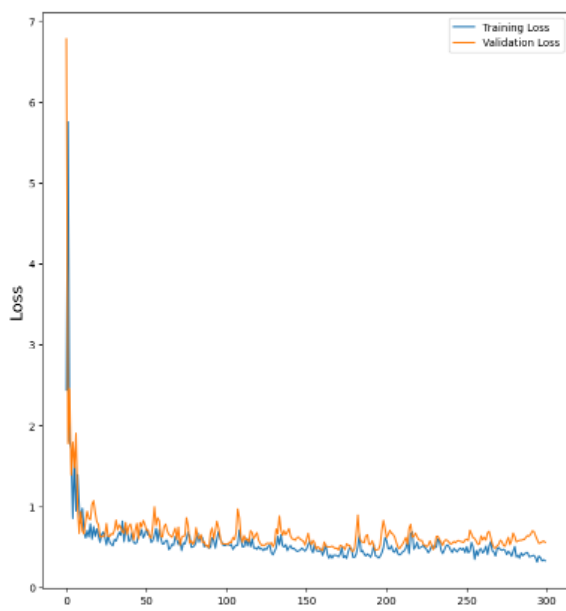
Dari beberapa kali percobaan yang dilakukan menggunakan dataset 1 yang berjumlah 253 gambar (data 1), dan menggabungkan dataset ke 1 dan 2 dengan jumlah keseluruhan sebanyak 3.123 gambar (data 2), diperoleh hasil:

Tabel I Hasil Eksperimen Arsitektur ViT

Epoch 50					
	loss	Val loss	Val accuracy	accuracy	Time
Data 1	0.8236	0.6380	0.7843	0.8039	2m
Data 2	0.1308	0.1515	0.9440	0.9616	15m
Epoch 100					
Data 1	0.7767	0.5920	0.7647	0.8235	3m
Data 2	0.1335	0.1381	0.9584	0.9748	30m
Epoch 150					
Data 1	0.6153	0.6035	0.7255	0.8824	5m
Data 2	0.0991	0.1676	0.9696	0.9728	45m
Epoch 200					
Data 1	0.5792	0.8201	0.5490	0.8824	6m
Data 2	0.0991	0.1676	0.9696	0.9728	60m
Epoch 300					
Data 1	0.4656	0.5533	0.8235	0.8824	9m
Data 2	0.0211	0.1673	0.9728	0.9792	70m


Accuracy Terbaik Deteksi tumor ini menggunakan data 2 yang berjumlah 3.123 gambar, accuracy yang dicapai sebesar 97,92% dengan iterasi sebanyak 300, sedangkan pada data ke 2 (jumlah dataset terkecil) dengan iterasi 300, accuracy maksimal yang bisa dicapai sebesar 88%.

Berikut Grafik Data 1:



Gambar 5. Grafik loss pada data 1 epoch 300


Pada gambar 5 Grafik loss dari data 1 dengan jumlah gambar 253 dan iterasi sebanyak 300. Training loss rata rata kurang dari 1%, dan validation loss pun sama kurang dari 1%.



Gambar 7. Confusion matrix data 1


Pada Gambar 7 menunjukkan bahwa Data 1, mampu memprediksi dengan benar gambar MRI yang terdeteksi Tumor otak sebesar 79%, dan memprediksi dengan benar gambar MRI yang tidak terdeteksi tumor otak sebesar 94%.

Berikut Grafik accuracy dari Data 2:




Gambar 6. Grafik Accuracy pada data 1 epoch 300

Pada gambar 6 Grafik Accuracy dari data 1 dengan jumlah gambar 253 dan iterasi sebanyak 300. Accuracy maksimal yang didapat 88%, dan validation accuracy sebesar 82%.




Gambar 8. Grafik loss pada data 2 epoch 300

Pada gambar 8 Grafik loss dari data 2 dengan jumlah gambar 3.123 dan iterasi sebanyak 300. Training loss rata rata kurang dari 1%, dan validation loss kurang dari 2%.



Gambar 9. Grafik Accuracy pada data 2 epoch 300

Pada gambar 9 Grafik Accuracy dari data 2 dengan jumlah gambar 3.123 dan iterasi sebanyak 300. Accuracy maksimal yang didapat 97,9%, dan validation accuracy sebesar 97,7%.



Gambar 10. Grafik Confusion Matrix dari Data 2

Pada Gambar 10 menunjukkan bahwa Data 2, mampu memprediksi dengan benar gambar MRI yang terdeteksi Tumor otak sebesar 90%, dan memprediksi dengan benar gambar MRI yang tidak terdeteksi tumor otak sebesar 99%.

4. Kesimpulan

Dari hasil deteksi Tumor otak melalui gambar MRI berdasarkan Arsitektur Vision Transformer menggunakan TensorFlow sebagai Platform dan Keras sebagai library, menghasilkan nilai akurasi rata rata di atas 97%, dengan beberapa experiment jumlah dataset, iterasi dan parameter model ViT menghasilkan tingkat akurasi yang baik.

Dari penelitian disimpulkan bahwa Arsitektur Vision Transformer sangat baik untuk mendeteksi Tumor Otak melalui gambar MRI, namun ViT memerlukan jumlah dataset dan iterasi yang banyak untuk mencapai tingkat akurasi yang optimal.

Referensi

- Adilah, T., 2022, Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine, Jurnal Infortech, Volume 4 No. 1 Juni 2022, E-ISSN: 2715-8160
- Alfikri, R. R., Utomo, M. S., Februriyanti, H., Nurwahyudi, e. A. (2022). Pembangunan Aplikasi Penerjemah Bahasa Isyarat Dengan Metode Cnn Berbasis Android. Jurnal Teknoinfo, 2(16), 183. <https://doi.org/10.33365/jti.v16i2.1752>.
- Chicho, B. T. and Sallow, A. B. (2021). A Comprehensive Survey Of Deep Learning Models Based On Keras Framework. Journal of Soft Computing and Data Mining, 2(2). <https://doi.org/10.30880/jscdm.2021.02.02.005>
- Chollet, F. 2017, Deep Learning with Python, Manning Publications Co.3 Lewis Street Greenwich, CT, Amerika Serikat
- Dao, Q. T., Cao, V., Do, L. N. L., Trinh, D. A. (2022). Design Of the Mobile-robot-based Surveillance System On University Campuses To Reduce The Effects Of Covid-19 Pandemic. Proceedings of the Sixth International Conference on Research in Intelligent and Computing. <https://doi.org/10.15439/2021r4>.
- Dosovitskiy, A., 2021, An Image Is Worth 16x16 Words:Transformers For Image Recognition At Scale, Published as a conference paper at ICLR 2021, arXiv:2010.11929v2
- Fattah, M. 2021, Pengolahan Citra Digital untuk Identifikasi Kanker Otak Menggunakan Metode Deep Belief Network (DBN), Jurnal Informatika Universitas Pamulang, Vol. 6, No. 4, Desember 2021 (735-742)
- Febrianti, A., 2020, Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine,

- JURNAL TEKNIK ITS Vol. 9, No. 1, (2020)
ISSN: 2337-3539
- Geron., A. 2019, Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow, Second Edition, O'REILLY
- Ghozali, M. (2021). Jurnal Review: Pengobatan Klinis Tumor Otak Pada Orang Dewasa. Jurnal Phi Jurnal Pendidikan Fisika Dan Fisika Terapan, 1(2), 1. <https://doi.org/10.22373/p-jpft.v2i1.8302>
- Goodfellow., I. 2016, Deep Learning (Adaptive Computation and Machine Learning series), The MIT press.
- Hope., T. 2017, Learning TensorFlow A Guide To Building Deep Learning Systems, O'reilly
- Houlsby., N. ., 10 July 2023, Transformers for Image Recognition at Scale, <https://ai.googleblog.com/2020/12/transformers-for-image-recognition-at.html>
- Kristian, M., Andryana, S., Gunaryati, A. (2021). Diagnosa Penyakit Tumor Otak Menggunakan Metode Waterfall Dan Algoritma Depth First Search. JIPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika), 1(6), 11-24. <https://doi.org/10.29100/jipi.v6i1.1840>.
- Loshchilov, I., 2017, Decoupled Weight Decay Regularization. arXiv preprint arXiv:1711.05101.
- Numpy Developer., 10 July 2023, Numpy Documentation . <https://numpy.org/devdocs/>
- PNPK Tumor otak, 2019, Pedoman Nasional Pelayanan Kedokteran Tumor Otak, Kementerian Kesehatan Republik Indonesia, Jakarta.
- Pravitasari, A., 2020, UNet-VGG16 with transfer learning for MRI-based brain tumor segmentation, Telkomnika (Telecommunication Computing Electronics and Control) (2020) 1310-1318, 18(3)
- Salman, L., 2022, Automated brain tumor detection of MRI image based on hybrid image processing techniques, Telkomnika (Telecommunication Computing Electronics and Control) (2022) 20(4) 762-771
- Suta, I., Hartati, R., Divayana, Y. (2019). Diagnosa Tumor Otak Berdasarkan Citra Mri (Magnetic Resonance Imaging). Majalah Ilmiah Teknologi Elektro, 2(18). <https://doi.org/10.24843/mite.2019.v18i02.p01>
- Tiku, J. C., Saputra, W. A., Prasetyo, N. A. (2022). Pengembangan Sistem Deteksi Memakai Masker Menggunakan Open Cv, Tensorflow Dan Keras. JURIKOM (Jurnal Riset Komputer), 4(9), 1183. <https://doi.org/10.30865/jurikom.v9i4.4739>.
- Winnarto, M., 2022, Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur Mobilenet V2, Jurnal SIMETRIS, Vol. 13 No. 2 November 2022
- Wulansari, A. and Rahman, A. T. (2022). Analisa Gambar Citra Mri Otak Dengan Watershed Dan Ekstraksi Fitur Glem. Jnanaloka, 39-46. <https://doi.org/10.36802/jnanaloka.2022.v3-no2-39-46>
- Zhao, Z. (2023). The Effect Of Input Size On the Accuracy Of A Convolutional Neural Network Performing Brain Tumor Detection. International Conference on Mechatronics Engineering and Artificial Intelligence (MEAI 2022). <https://doi.org/10.1117/12.2672694>.