

Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network

Retno Wardhani¹, Nur Nafi'iyah^{2*)}

^{1,2}Teknik Informatika, Universitas Islam Lamongan, Lamongan

^{1,2}Veteran 53A Lamongan, 62211, Jawa Timur

email: ¹retzno@yahoo.com, ²mynaff@unisla.ac.id

Abstract – The science of artificial intelligence and computer vision is beneficial in facilitating the detection of diseases in the medical field. Computer-based disease detection can save time. However, identifying and detecting tumors on MRI images require seriousness and is time-consuming. Due to the diversity of structures in size, shape, and intensity of the image, accuracy is needed in identifying the original organ structure and the diseased one. Previous studies have proposed a method for identifying brain tumors to produce the correct precision. In previous studies, neural network-based methods have good accuracy. We present five Convolutional Neural Network (CNN) architectures for identifying brain tumors (glioma, meningioma, no tumor, and pituitary) on MRI images. This study aims to develop an optimal CNN architecture for identifying tumors. We use the dataset from Kaggle with a total training data of 5712 and testing of 1311. Of the five proposed CNN architectures, architecture c has the highest accuracy of 82.2% with an unlimited number of parameters of 29605060. A good CNN architecture has many convolution layers. We also compare the proposed architecture with CNN transfer learning (Inception, ResNet-50, and VGG16), and with CNN transfer learning architecture, the accuracy is higher than our proposed architecture.

Keywords - CNN architecture, brain tumor identification, MRI.

Abstrak – Ilmu kecerdasan buatan dan komputer vision sangat bermanfaat untuk memudahkan deteksi penyakit di bidang kedokteran. Deteksi penyakit dengan berbasis komputer dapat mengefisienkan waktu. Akan tetapi identifikasi dan deteksi tumor pada citra MRI membutuhkan keseriusan dan memakan waktu. Karena adanya keberagaman struktur ukuran, bentuk dan intensitas citra, maka diperlukan ketelitian dalam mengenali antara struktur yang organ asli dengan yang penyakit. Beberapa penelitian sebelumnya mencoba mengusulkan metode untuk identifikasi tumor otak agar menghasilkan presisi yang tepat. Pada penelitian sebelumnya metode berbasis neural network mempunyai presisi yang baik. Kami mengusulkan lima arsitektur Convolutional Neural Network (CNN) untuk identifikasi tumor otak (glioma, meningioma, notumor, dan pituitary) citra MRI. Tujuan penelitian ini menyusun arsitektur CNN yang optimal dalam mengidentifikasi tumor. Kami menggunakan dataset dari kaggle dengan total data training 5712, dan testing 1311. Dari lima arsitektur CNN yang diusulkan, akurasi yang paling tinggi adalah 82.2% pada arsitektur c dengan jumlah total parameter 29605060. Arsitektur CNN yang baik mempunyai layer convolution yang banyak. Kami juga membandingkan arsitektur usulan dengan transfer learning CNN (Inception,

ResNet-50, dan VGG16), dan dengan arsitektur transfer learning CNN akurasi lebih tinggi dibandingkan arsitektur usulan Kami.

Kata Kunci – arsitektur CNN, identifikasi tumor otak, MRI.

I. PENDAHULUAN

Pada tahun 2016 penyebab utama kematian di Amerika Serikat adalah tumor otak. Tumor otak merupakan jenis kanker yang umum terjadi di anak dan remaja. Beberapa jenis tumor otak membutuhkan penanganan medis yang berbeda. Dalam sistem diagnosis yang menggunakan komputer, massa tumor harus diidentifikasi dan disegmentasi sebelum dilakukan klasifikasi jenis tumor [1].

Penelitian tentang identifikasi dan segmentasi tumor sudah banyak yang melakukan, akan tetapi masih kurangnya akurasi yang tepat. Teknologi kecerdasan buatan dan komputer vision dengan metode deep neural network dapat digunakan sebagai solusi dalam membantu mengidentifikasi tumor dengan optimal. Ada banyak metode yang digunakan dalam beberapa penelitian terkait ekstraksi fitur dan klasifikasi tumor otak. Metode ekstraksi fitur pada penelitian sebelumnya diantaranya geometri (luas tumor, luas tempurung), dan statistik nilai grayscale citra [2]; LDA (Linear Discriminant Analysis) [3]; eigenbrain otak [4]; Wavelet Transform [5], [6], [7]; Histogram of Oriented Gradient (HOG) [8]; Grey-level co-occurrence matrix (GLCM) [9].

Perkembangan teknologi membuat proses klasifikasi tumor otak menjadi lebih efisien. Metode yang akhir-akhir ini digunakan dalam identifikasi tumor otak adalah Neural Network Deep Learning [10], [11], Convolutional Neural Network [12], [13], [14], [15], [16]. Hasil akurasi metode CNN (Convolutional Neural Network) dalam klasifikasi tumor otak di atas 90%. Metode CNN melakukan proses ekstraksi fitur dan klasifikasi secara otomatis. Oleh karena itu Kami melakukan identifikasi tumor otak menggunakan metode CNN dengan arsitektur dari penelitian [1]. Perbedaan penelitian Kami dengan penelitian sebelumnya [1] dari ukuran citra input, jumlah neuron dalam setiap layer convolution, layer hidden, dan Kami membandingkan dengan model pretrained VGG16, InceptionV3, dan ResNet-50.

II. PENELITIAN YANG TERKAIT

Penelitian terkait identifikasi tumor otak mempunyai tantangan, dikarenakan ada keberagaman yang kompleks mengenai ukuran, bentuk, dan intensitas dari citra. Berbagai metodologi telah dikembangkan untuk identifikasi tumor otak

*) penulis korespondensi: Nur Nafi'iyah
Email: mynaff@unisla.ac.id


citra MRI. Mulai dari metode tradisional (machine learning), atau yang berbasis jaringan (neural network).

Beberapa penelitian identifikasi tumor otak: Mengklasifikasi tumor otak (Glioma, Meningioma, and Pituitary) dengan CNN [1]. Mengklasifikasi jenis tumor (normal dan abnormal) berdasarkan fitur geometri dengan metode Naive Bayes [2]. Mengklasifikasi tumor dengan metode SVM dari ekstraksi ciri LDA citra [3]. Menentukan tumor (normal, glioma, metastatis) berdasarkan eigenbrain [4]. Mengklasifikasi tumor otak dengan metode ekstraksi fitur wavelet [5], [6], [7]. Sebagian besar metode yang digunakan identifikasi tumor otak adalah neural network (deep learning atau CNN) dan rata-rata akurasi 70% sampai 90% [9], [10], [11], [12], [13], [14], [15], [16]. Berdasarkan hasil akurasi pada penelitian sebelumnya, metode CNN lebih unggul. Oleh karena itu, Kami menggunakan metode CNN untuk identifikasi tumor otak (glioma, meningioma, normal, pituitary). Oleh karena itu Kami melakukan identifikasi tumor otak menggunakan metode CNN dengan arsitektur dari penelitian [1]. Perbedaan penelitian Kami dengan penelitian sebelumnya [1] dari ukuran citra input, jumlah neuron dalam setiap layer convolution, layer hidden, dan Kami membandingkan dengan model pretrained VGG16, InceptionV3, dan ResNet-50.

III. METODE PENELITIAN

A. Dataset

Kami menggunakan dataset dari Kaggle [17]. Tabel 1 menjelaskan pembagian dataset dan jenis kelas tumor otak, yaitu Glioma, Meningioma, No tumor, dan Pituitary. Gambar 1 (a) contoh tumor jenis glioma, Gambar 1 (b) contoh tumor jenis meningioma, dan Gambar 1 (c) tumor jenis pituitary.



Gbr. 1 (a) Tumor Glioma (b) Tumor Meningioma (c) Tumor Pituitary

B. Convolutional Neural Network

Gambar 2 merupakan usulan arsitektur dalam identifikasi tumor otak. Kami mengacu pada penelitian Abiwinanda et al., terdapat lima arsitektur CNN yang diusulkan [1]. Kami mengusulkan lima arsitektur yang berbeda dengan penelitian sebelumnya adalah ukuran gambar input, dan jumlah neuron pada setiap layer convolution dan hidden. Gambar 2 (a)

sampai (e) adalah arsitektur CNN yang digunakan untuk identifikasi tumor otak.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 127, 127, 64)	0
flatten (Flatten)	(None, 1032256)	0
dense (Dense)	(None, 256)	264257792
dense_1 (Dense)	(None, 4)	1028
Total params: 264,260,612		
Trainable params: 264,260,612		
Non-trainable params: 0		

(a)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 127, 127, 64)	0
conv2d_1 (Conv2D)	(None, 125, 125, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 64)	0
flatten (Flatten)	(None, 246016)	0
dense (Dense)	(None, 256)	62980352
dense_1 (Dense)	(None, 4)	1028
Total params: 63,020,100		
Trainable params: 63,020,100		
Non-trainable params: 0		

(b)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 127, 127, 64)	0
conv2d_1 (Conv2D)	(None, 125, 125, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 64)	0
conv2d_2 (Conv2D)	(None, 60, 60, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 30, 30, 128)	0
flatten (Flatten)	(None, 115200)	0
dense (Dense)	(None, 256)	29491456
dense_1 (Dense)	(None, 4)	1028
Total params: 29,605,060		
Trainable params: 29,605,060		
Non-trainable params: 0		

(c)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 127, 127, 64)	0
flatten (Flatten)	(None, 1032256)	0
dense (Dense)	(None, 256)	264257792
dense_1 (Dense)	(None, 256)	65792
dense_2 (Dense)	(None, 4)	1028
Total params: 264,326,404		
Trainable params: 264,326,404		
Non-trainable params: 0		

(d)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 64)	1792
max_pooling2d (MaxPooling2D)	(None, 127, 127, 64)	0
flatten (Flatten)	(None, 1032256)	0
dense (Dense)	(None, 256)	264257792
dense_1 (Dense)	(None, 256)	65792
dense_2 (Dense)	(None, 512)	131584
dense_3 (Dense)	(None, 4)	2052
Total params: 264,459,012		
Trainable params: 264,459,012		
Non-trainable params: 0		

(e)

Gbr. 2 Arsitektur CNN Usulan

TABEL I
DATASET PENYAKIT TUMOR

Jenis	Training	Testing
Glioma	1321	300
Meningioma	1339	306
Notumor	1595	405
Pituitary	1457	300
Total	5712	1311

IV. HASIL DAN PEMBAHASAN


Tabel II merupakan hasil ujicoba identifikasi tumor otak dengan arsitektur yang Kami usulkan. Kami mengidentifikasi tumor otak menjadi empat kelas (glioma, meningioma, normal/notumor, pituitary). Kami membuat model (training) dengan epoch 20, dan setiap epoch membaca 200 gambar. Proses training menggunakan optimizer rmsprop dengan learning rate default, dan loss function categorical crossentropy. Proses ujicoba/testing dengan menghitung akurasi. Tabel II menampilkan hasil evaluasi (nilai akurasi ujicoba citra, dan jumlah parameter/bobot dari setiap arsitektur).

TABEL III
HASIL EVALUASI TESTING


Metode	Parameter	Akurasi (%)
Arsitektur (a)	264260612	72.6
Arsitektur (b)	63020100	81.9
Arsitektur (c)	29605060	82.2
Arsitektur (d)	264326404	74.1
Arsitektur (e)	264459012	74.2
Inception	22097700	79.5
ResNet-50	24112004	94.1
VGG16	14845764	93

Gambar 3 merupakan grafik akurasi saat training dan testing. Berdasarkan Gambar 3, nilai akurasi proses training dan testing mempunyai selisih rata-rata 0.3. Model yang diperoleh dari training kurang baik, karena hasil akurasi saat testing di bawah training.


Gambar 4 merupakan grafik loss function saat training dan testing. Berdasarkan Gambar 4, nilai loss proses training dan testing mempunyai selisih rata-rata 0.3. Model yang diperoleh dari training kurang baik, karena hasil loss saat testing di atas training.




(a)




(b)




(c)



(d)




(b)




(e)


Gbr. 3 Hasil Evaluasi Akurasi




(c)



(a)



(d)



Gbr. 4 Hasil Evaluasi Loss Function

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 256, 256, 3)]	0
inception_v3 (Model)	(None, 6, 6, 2048)	21802784
flatten (Flatten)	(None, 73728)	0
dense (Dense)	(None, 4)	294916
Total params: 22,097,700		
Trainable params: 294,916		
Non-trainable params: 21,802,784		

(a) Inception




Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 256, 256, 3)]	0
resnet50 (Model)	(None, 8, 8, 2048)	23587712
flatten (Flatten)	(None, 131072)	0
dense (Dense)	(None, 4)	524292
Total params: 24,112,004		
Trainable params: 524,292		
Non-trainable params: 23,587,712		

(b) ResNet50


Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 256, 256, 3)]	0
vgg16 (Model)	(None, 8, 8, 512)	14714688
flatten (Flatten)	(None, 32768)	0
dense (Dense)	(None, 4)	131076
Total params: 14,845,764		
Trainable params: 131,076		
Non-trainable params: 14,714,688		

(c) VGG16

Gbr. 5 Parameter Pretrained CNN



Gbr. 6 Hasil Akurasi Pretrained CNN



Gbr. 7 Hasil Loss Function Pretrained CNN

Gambar 5 merupakan pretrained CNN yang digunakan untuk identifikasi tumor otak. Kami membandingkan model arsitektur yang Kami usulkan dengan model pretrained CNN (VGG16, Inception, dan ResNet50). Gambar 6 merupakan hasil evaluasi akurasi, dan Gambar 7 merupakan hasil loss

function dari pretrained CNN. Model arsitektur yang diusulkan mempunyai akurasi tertinggi 82.2% pada arsitektur c. Sedangkan akurasi pretrained tertinggi adalah 94.1% pada CNN ResNet50. Berarti model arsitektur CNN usulan Kami baik jika layer convolution lapisannya banyak, berdasarkan akurasi tertinggi pada arsitektur c. Gambar 3 menunjukkan akurasi saat training dan testing metode CNN kelima arsitektur yang diusulkan. Gambar 4 performa loss saat training dan testing. Berdasarkan Gambar 3 dan Gambar 4 perbedaan akurasi dan loss data training dan testing berbeda lebih tinggi akurasi data training, dan lebih rendah loss data training, berarti arsitektur CNN usulan underfitting, karena beberapa titik akurasi ataupun loss berbeda.

V. KESIMPULAN

Kami mengusulkan identifikasi tumor otak (glioma, meningioma, normal/notumor, pituitary) dengan metode CNN. Kami mengusulkan lima arsitektur CNN, dan membandingkan dengan pretrained CNN (VGG16, Inception, dan ResNet50). Hasil akurasi tertinggi adalah arsitektur c 82.2%, dan pretrained CNN ResNet50 94.1%.

UCAPAN TERIMA KASIH

Terima kasih kepada Litbang Pemas Universitas Islam Lamongan.

DAFTAR PUSTAKA

- [1] N. Abiwinanda, M. Hanif, S. T. Hesaputra, A. Handayani, and T. R. Mengko, "Brain tumor classification using convolutional neural network," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11993 LNCS, pp. 335–342, 2020, doi: 10.1007/978-3-030-46643-5_33.
- [2] F. Akbar, A. N. Rais, I. A. Sobari, R. A. Zuama, and B. Rudiarto, "Analisis Performa Algoritma Naive Bayes pada Deteksi Otomatis Citra MRI," *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 5, no. 1, 2019, doi: 10.33480/jitk.v5i1.586.
- [3] A. Adinegoro, R. D. Atmaja, and R. Purnamasari, "Deteksi Tumor Otak dengan Ekstraksi Ciri & Feature Selection menggunakan Linear Discriminant Analysis (LDA) dan Support Vector Machine (SVM)," *e-Proceeding Eng.*, vol. 2, no. 2, pp. 2532–2539, 2015.
- [4] I. Soesanti, A. Susanto, T. Widodo, and M. Tjokronagoro, "Ekstraksi Ciri dan Identifikasi Citra Otak MRI Berbasis Eigenbrain Image," *Forum Tek.*, vol. 34, no. 1, 2011.
- [5] L. W. Astuti, "Ekstraksi Fitur Citra MRI Otak Menggunakan Data Wavelet Transform (DWT) untuk Klasifikasi Penyakit Tumor Otak," *J. Ilm. Inform. Glob.*, vol. 10, no. 2, pp. 80–86, 2019, doi: 10.36982/jig.v10i2.854.
- [6] S. Kumar, C. Dabas, and S. Godara, "Classification of Brain MRI Tumor Images: A Hybrid Approach," *Procedia Comput. Sci.*, vol. 122, pp. 510–517, 2017, doi: 10.1016/j.procs.2017.11.400.
- [7] N. Varuna Shree and T. N. R. Kumar, "Identification and classification of brain tumor MRI images with feature extraction using DWT and probabilistic neural network," *Brain Informatics*, vol. 5, no. 1, 2018, doi: 10.1007/s40708-017-0075-5.
- [8] T. A. M and Q. N. Azizah, "Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine," vol. 4, no. 1, pp. 45–50, 2022.
- [9] W. Widhiarso, Y. Yohannes, and C. Prakarsah, "Brain Tumor Classification Using Gray Level Co-occurrence Matrix and Convolutional Neural Network," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 8, no. 2, p. 179, 2018, doi: 10.22146/ijeis.34713.
- [10] M. Aamir et al., "A deep learning approach for brain tumor classification using MRI images," *Comput. Electr. Eng.*, vol. 101, no. May, p. 108105, 2022, doi: 10.1016/j.compeleceng.2022.108105.
- [11] Y. Gu and K. Li, "A Transfer Model Based on Supervised Multi-Layer Dictionary Learning for Brain Tumor MRI Image Recognition," *Front. Neurosci.*, vol. 15, 2021, doi:

- 10.3389/fnins.2021.687496.
- [12] M. C. Daniel and L. M. Ruxandra, "Brain Tumor Classification Using Pretrained Convolutional Neural Networks," *2021 16th Int. Conf. Eng. Mod. Electr. Syst. EMES 2021 - Proc.*, vol. 11, no. September, pp. 1457–1461, 2021, doi: 10.1109/EMES52337.2021.9484102.
- [13] H. P. A. Tjahyaningtijas *et al.*, "Brain Tumor Classification in MRI Images Using En-CNN," *Int. J. Intell. Eng. Syst.*, vol. 14, no. 4, 2021, doi: 10.22266/ijies2021.0831.38.
- [14] S. Deepak and P. M. Ameer, "Brain tumor classification using deep CNN features via transfer learning," *Comput. Biol. Med.*, vol. 111, no. June, p. 103345, 2019, doi: 10.1016/j.combiomed.2019.103345.
- [15] P. Harish and S. Baskar, "MRI based detection and classification of brain tumor using enhanced faster R-CNN and Alex Net model," *Mater. Today Proc.*, no. xxxx, 2020, doi: 10.1016/j.matpr.2020.11.495.
- [16] E. Irmak, "Multi-Classification of Brain Tumor MRI Images Using Deep Convolutional Neural Network with Fully Optimized Framework," *Iran. J. Sci. Technol. - Trans. Electr. Eng.*, vol. 45, no. 3, 2021, doi: 10.1007/s40998-021-00426-9.
- [17] Kaggle, "Dataset MRI." <https://www.kaggle.com/masoudnickparvar/brain-tumor-mri-dataset>.