

Deteksi Dini Tumor Otak Menggunakan Metode Deep Learning Arsitektur CNN Resnet-152

Aji Digdoyo ¹⁾, Tri Surawan ^{1,*}, Adhitho Satyo Bayangkari Karno ²⁾, Diyah Ruri Irawati ³⁾, dan Yasin Efendi ⁴⁾

¹ Teknik Mesin, Universitas Jayabaya, Jakarta

² Fakultas Teknologi Informasi, Universitas Gunadarma, Jakarta

³ Manajemen Informatika; STMIK Jakarta STI&K, Jakarta

⁴ Fakultas Ilmu Pendidikan; Universitas Muhammadiyah, Jakarta

*) *Corresponding author*: tri.surawan@gmail.com

(Received: 28 Oct 2021 • Revised: 23 May 2022 • Accepted: 30 May 2022)

Abstract

Tumor disease in Indonesia occupies the 5th largest mortality rate after diabetes, stroke, kidney and high blood pressure. Lack of early treatment, the number of paramedics and minimal equipment are the main causes of the high mortality rate. Artificial Intelligence (AI) has a high potential to contribute to helping patients and medical professionals diagnose tumors directly, quickly and cheaply. One of the AI methods used in this research is CNN with ResNet-152 architecture. By training and validating a total of 2,870 images, the accuracy values are 99% and 81%, respectively. To further ensure the desired results, the model obtained from the training was reused for testing, with the results of an accuracy value of 96% and the accuracy for each class being glioma (97%), meningioma (95%), no_tumor (98%) and pituitary (96%).

Abstrak

Penyakit tumor di Indonesia menduduki tingkat kematian terbesar ke-5 setelah diabetes, stroke, ginjal dan darah tinggi. Kurangnya penanganan dini, jumlah paramedis dan peralatan yang minim adalah penyebab utama tingginya tingkat kematian. *Artificial Intelligence* (AI) memiliki potensi tinggi untuk berkontribusi membantu pasien dan para medis mendiagnosa tumor secara langsung, cepat dan murah. Salah satu metode AI dipergunakan dalam penelitian ini adalah CNN dengan arsitektur ResNet-152. Dengan melakukan *training* dan validasi sejumlah 2.870 *image* menghasilkan nilai akurasi masing-masing 99% dan 81%. Untuk lebih memastikan hasil yang diinginkan, maka model yang diperoleh dari *training* dipergunakan kembali untuk pengujian, dengan hasil nilai akurasi sebesar 96% dan akurasi untuk tiap kelas adalah glioma (97%), meningioma (95%), no_tumor (98%) dan pituitary (96%).

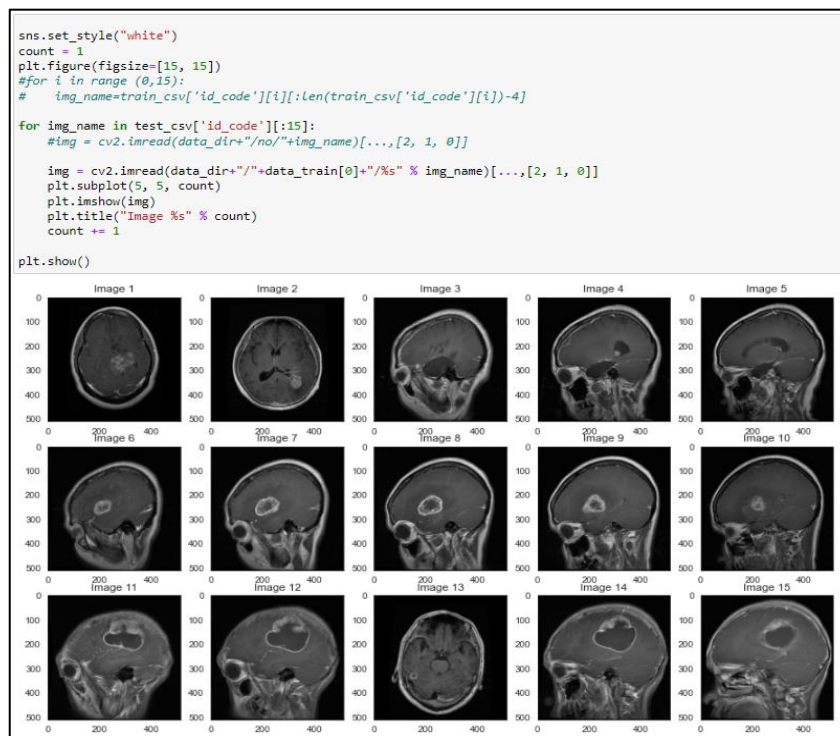
Keywords: *Convolution Neral Network, CT Scan, Deep Learning, Inception Resnet, Tumor Brain*

PENDAHULUAN

Pertumbuhan sel pada tubuh manusia merupakan suatu hal yang wajar namun jika pertumbuhannya tak terkendali dapat mengakibatkan berbagai macam gangguan penyakit pada manusia [1]. Untuk pertumbuhan sel tak wajar di sekitar otak manusia disebut dengan tumor otak. Jika awal keberadaan tumor otak ada di bagian kepala lalu menyebar di sekitar otak dan kepala, para medis menyebutnya dengan tumor primer. Sedangkan tumor sekunder adalah tumor yang menyebar kebagian otak manusia yang berasal dari bagian tubuh lainnya. Penyebab dari penyakit tumor sampai saat ini pun masih belum diketahui [2].

Tumor dengan pertumbuhan lambat tidak banyak menimbulkan efek pada manusia, berlawanan dengan tumor yang pertumbuhannya sangat cepat (tumor ganas) dapat menimbulkan pengaruh lain yang tidak normal [3]. Di dunia, tumor merupakan penyebab kematian kedua setelah jantung. Di Indonesia, tumor merupakan penyebab kematian di posisi 5 setelah ginjal, diabetes, stroke dan darah tinggi [4]. Untuk negara maju penderita tumor cukup tinggi tapi angka kematian kecil. Tingkat pelayanan kesehatan, jumlah para medis dan peralatan pendukung kedokteran sudah sangat baik sehingga mampu menekan jumlah kematian. Sedangkan untuk negara berkembang rasio tingkat kematian sangat tinggi dibandingkan dengan kasus yang ada. Kurangnya penanganan dini dan pasien datang ke unit medis sudah dalam kondisi stadium tinggi menjadi faktor proses pemulihan yang sulit. Selain itu jumlah para medis dan ketersediaan peralatan pendukung yang sangat terbatas juga menjadi faktor sulitnya proses pemulihan para pasien tumor otak.

Diagnosa tumor otak dari *dataset image* yang dihasilkan dari peralatan *Computer Tomography Scanner (CT scan)* hanya dapat dilakukan oleh paramedis dengan keahlian khusus. *Artificial Intelligence (AI)* dapat membantu para medis dan pasien untuk dapat memprediksi tumor otak dari *image CT Scan* dengan cepat, akurat dan biaya yang terjangkau. Salah satu metode AI, yaitu *Convolution Neural Network (CNN)* melakukan training dari sejumlah *image CT Scan*. Hasil training berupa model fitur, lalu dilakukan proses klasifikasi untuk memprediksi suatu *image* tak berlabel (Gambar 1).




Gambar 1. *Dataset Image Tumor Brain*

Secara klinis diagnosa tumor otak dibedakan menjadi 4 kelas, yaitu [4]:


- Glioma (tumor di sel glial)
- Meningoma (tumor pertumbuhan lambat)
- No_tumor (normal)
- Pituitary (tumor mengekpresi hormon)

Dengan mempertimbangkan performa komputer yang digunakan dan akurasi yang diharapkan, maka dalam penelitian ini dipilih arsitektur ResNet-152 yang mampu dijalankan bersama *library tensorflow* [5] (Gambar 2). [6]



Gambar 2. Komparasi ResNet-152 dengan model lainnya

Pada tahun 2015 struktur jaringan ResNet dirancang pertama kali oleh He Kaiming dan Sun Jian [7]. Dalam jaringan ini dipergunakan residual blok dan struktur *bottleneck* untuk mengatasi efek *overfitting* [8] yang timbul karena jaringan yang semakin dalam seperti yang terdapat pada Gambar 3.



Gambar 3. Blok Residual (kiri) dan struktur bottleneck (kanan)

METODE PENELITIAN

Dalam penelitian ini dipergunakan dataset untuk *training* 2.870 *image* (sumber kaggle). Setiap *image* diklasifikasikan ke dalam 4 kelas dengan jumlah dataset tiap kelas [9] yaitu (Gambar 4):

0 – Glioma	826 image (28,8%)
1 – Meningoma	822 image (28,6%)
2 – No_tumor	395 image (13,8%)
3 – Pituitary	827 image (28,8%)



Gambar 4. Pie dan histogram dataset

Dataset sebanyak 2.870 *image*, dibagi menjadi dataset untuk proses *training* dan dataset untuk validasi dengan melakukan *split* sebesar 20%. Ukuran *image* mempergunakan 224x224 pixel, dan *batch size*=32. Untuk pemrosesan *augmentasi image* mempergunakan *library Image Data Generator*, yaitu rotasi 40°, flip horizontal, pergeseran panjang, lebar, *zoom* masing-masing 20% dari ukuran *image dataset* (Gambar 5). Hasil proses ini diperoleh 573 dan 2297 *image* terdiri dari 4 kelas (Glioma, Meningoma, No_tumor, dan Pituitary)

```
In [13]: IMAGE_SIZE=(224,224)
         BATCH_SIZE=32

         datagen_kwargs = dict(rescale=1./255, validation_split=.20)
         dataflow_kwargs = dict(target_size=IMAGE_SIZE, batch_size=BATCH_SIZE,
                                interpolation="bilinear")

         valid_datagen = tf.keras.preprocessing.image.ImageDataGenerator(
             **datagen_kwargs)
         valid_generator = valid_datagen.flow_from_directory(
             data_dir, subset="validation", shuffle=False, **dataflow_kwargs)

         do_data_augmentation = True #@param {type:"boolean"}
         if do_data_augmentation:
             train_datagen = tf.keras.preprocessing.image.ImageDataGenerator(
                 rotation_range=40,
                 horizontal_flip=True,
                 width_shift_range=0.2, height_shift_range=0.2,
                 shear_range=0.2, zoom_range=0.2,
                 **datagen_kwargs)
         else:
             train_datagen = valid_datagen

         train_generator = train_datagen.flow_from_directory(
             data_dir, subset="training", shuffle=True, **dataflow_kwargs)

         Found 573 images belonging to 4 classes.
         Found 2297 images belonging to 4 classes.
```

Gambar 5. Tahap proses augmentasi dataset

Dengan menggunakan base model ResNet152V2 dari tensorflow keras, dengan kode sebagai berikut :

base_model=tf.keras.applications.ResNet152V2(input_shape=(224,224,3),include_top=False,weights="imagenet")

kemudian dibentuk *sequence* yaitu dengan menambahkan 3 lapisan yang masing-masing terdiri dari *Dropout*, *Flatten*, *Batch Normalization*, dan *Dense*), sebagai *filter* menggunakan fungsi *activation* ‘relu’. Keseluruhan model yang dibentuk dapat dilihat pada Gambar 6.

```

model.build((None,)+IMAGE_SIZE+(3,))
model.summary()
Model: "sequential"

```

Layer (type)	Output Shape	Param #
resnet152v2 (Functional)	(None, 7, 7, 2048)	58331648
dropout (Dropout)	(None, 7, 7, 2048)	0
flatten (Flatten)	(None, 100352)	0
batch_normalization (Batch Normalization)	(None, 100352)	401408
dense (Dense)	(None, 256)	25690368
batch_normalization_1 (Batch Normalization)	(None, 256)	1024
activation (Activation)	(None, 256)	0
dropout_1 (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 128)	32896
batch_normalization_2 (Batch Normalization)	(None, 128)	512
activation_1 (Activation)	(None, 128)	0
dropout_2 (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 32)	4128
batch_normalization_3 (Batch Normalization)	(None, 32)	128
activation_2 (Activation)	(None, 32)	0
dense_3 (Dense)	(None, 4)	132

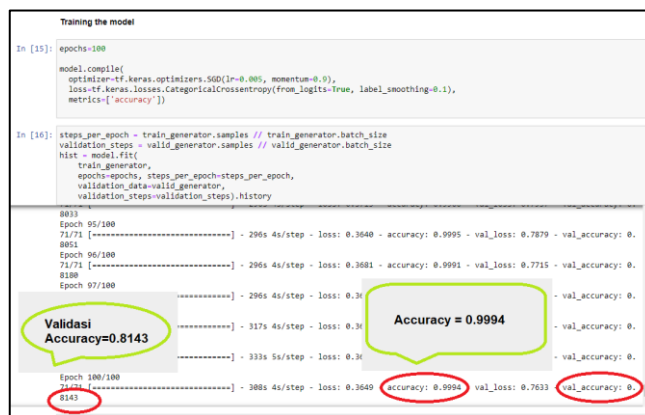
```

Total params: 84,462,244
Trainable params: 29,345,124
Non-trainable params: 55,117,120

```


Gambar 6. Model lapisan *Deep Learning*

Dari model yang telah dibuat selanjutnya dilakukan proses *training* dengan 100 epoch, optimasi menggunakan SGD (*Stochastic Gradient Descent*), *learning rate* (lr) 0.005, dan perhitungan *loss* dengan metode *Categorical Crossentropy* dengan metric pengukuran *accuracy*. Hasil dari proses *training* adalah nilai akurasi 99%, dan akurasi validasi 81%. (Gambar 7).




Gambar 7. *History training* dan validasi

Selain tampilan *history* per epoch (Gambar 7), *tool library matplotlib* dapat dipergunakan untuk menampilkan visual grafik kontinu dari akurasi dan *loss* dari proses *training* dan *testing* (validasi). Terlihat bahwa antara epoch 0-20, terjadi penurunan *loss* yang sangat tajam, selanjutnya grafik akan menjadi datar di kisaran 0.7 untuk validasi dan 0.3 untuk *training* (Gambar 8). Untuk grafik akurasi terjadi peningkatan sangat tajam antara 0-20 epoch, kemudian grafik akan menjadi datar di kisaran 0.9 untuk proses *training* dan 0.8 untuk *testing* (validasi) (Gambar 9).



Gambar 8. Grafik *loss training* dan *testing* (val)



Gambar 9. Grafik akurasi *training* dan *testing* (val)

HASIL DAN PEMBAHASAN


Model hasil *training* dipergunakan untuk memprediksi data *image* tak berlabel. Untuk memperoleh akurasi *testing* dilakukan pengujian acak terhadap 2870 *image*. Untuk mengukur presisi akurasi hasil prediksi terhadap data *testing*, dipergunakan modul *sklearn python* dengan menghitung nilai akurasi data hasil prediksi dan data real (dengan label yang telah diketahui) dalam bentuk visualisasi matrik cofusion [10], seperti yang ditampilkan dalam Gambar 10 dan Gambar 11.

```

: from sklearn.metrics import confusion_matrix, accuracy_score
  import seaborn as sn
  print(accuracy_score(y_test_class, y_pred))
  confusion_matrix(y_test_class, y_pred)

0.9641114982578397

: array([[795, 29,  0,  2],
        [ 17, 775,  0, 30],
        [  1,  4, 390,  0],
        [  4,  9,  7, 807]], dtype=int64)
    
```



Gambar 10. Tabel dan Matrik Confusion

```

#CLASSIFICATION REPORT
from sklearn.metrics import classification_report
print(classification_report(y_test_n, y_prediction_n, target_names=class_names))
    
```

	precision	recall	f1-score	support
glioma_tumor	0.97	0.96	0.97	826
meningioma_tumor	0.95	0.94	0.95	822
no_tumor	0.98	0.99	0.98	395
pituitary_tumor	0.96	0.98	0.97	827
accuracy			0.96	2870

Gambar 11. Report Klasifikasi

Report klasifikasi (Gambar 11) adalah hasil perhitungan lanjut (*resume*) dari hasil prediksi benar dan salah yang dinyatakan dalam bentuk tabel dan matrik confusion (Gambar 10). Untuk dapat mengetahui detail perhitungan dari table dan matrik confusion menjadi report klasifikasi, dapat diuraikan dalam Tabel 1.

Tabel 1. Penjelasan report klasifikasi

Glioma	A
Meningoma	B
No umor	C
Pituatary	D

		Sebenarnya				
		A	B	C	D	Support
Pred	A	795	29	0	2	826
	B	17	775	0	30	822
	C	1	4	390	0	395
	D	4	9	7	807	827
		817	817	397	839	2.870

	Precision	Recall	f1-score
A	$795/817 = 0.97$	$795/826 = 0.96$	$2*795/(817+826) = 0.97$
B	$775/817 = 0.95$	$775/822 = 0.94$	$2*775/(817+822) = 0.95$
C	$390/397 = 0.98$	$390/395 = 0.99$	$2*390/(397+395) = 0.98$
D	$807/839 = 0.96$	$807/827 = 0.98$	$2*807/(839+827) = 0.97$

$$Accuracy = (795+775+390+807)/2870 = 0.96$$

Hasil pengujian dengan menggunakan data *testing*, mesin *learning* berhasil memprediksi dengan nilai presisi tiap kelas, adalah glioma (97%), meningioma (95%), no_tumor (98%) dan pituatory (96%).

KESIMPULAN

Hasil dari penelitian ini sangat baik karena dari hasil pengujian diperoleh nilai akurasi 96%, dengan rincian akurasi tiap kelas sebagai berikut glioma (97%), meningioma (95%), no_tumor (98%) dan pituatory (96%). Hasil akan dapat lebih baik lagi dengan menggunakan arsitektur yang lebih dalam dengan konsekuensi memerlukan performa komputer yang lebih tinggi dan juga waktu operasi lebih lama. Model dari hasil penelitian, dapat ditanam (*embed*) ke dalam sistem yang berbasis web atau *mobile* sehingga pasien dapat melakukan pendeteksian mandiri secara langsung (*real time*) dengan cepat, akurat dan tanpa biaya.

DAFTAR PUSTAKA

- [1] P. Kleihues, J. B-Sloan, and H. Ohgaki, Tumours of the nervous system, Lyon: International Agency for Research on Cancer, 2014, p. 511
- [2] D. Yulianti, E. Syahrudin, A. Hudoyo, and A. Icksan, "Gejala Klinis Neurologis dan Gambaran CT Scan Otak Pasien Kanker Paru Karsinoma Bukan Sel Kecil Metastasis ke Otak di Rumah Sakit Persahabatan," *Indonesian Journal of Cancer*, vol. 4, no. 1, 2010.
- [3] Anonym, "General Information About Adult Brain Tumors". NCI. 14 April 2014. Archived from the original on 5 July 2014. Retrieved 8 June 2014.

- [4] A. Pulvirenti, *et al.*, Quantitative Computed Tomography Image Analysis to Predict Pancreatic Neuroendocrine Tumor Grade. DOI: 10.1200/CCI.20.00121 JCO Clinical Cancer Informatics no. 5, pp. 679-694, 2021.
- [5] K. M. Brindle, J. Richard, Mair, and A. J. Wright, Brain Tumor Imaging. DOI: 10.1200/JCO.2017.72.7636 Journal of Clinical Oncology 35, no. 21 (July 20, 2017) 2432-2438.
- [6] Anonym, "Arxiv," Cornell University, [Online]. Available: <https://arxiv.org/>. [Accessed December 2021].
- [7] A. S. B. Karno, W. Hastomo, Y. Efendi, D. R. Irawati, Future Prediction Of Covid-19 In Indonesia Using Deep Learning. Seminar Nasional Teknologi Informasi dan Komunikasi (SENATIK)-2020. E-ISSN:2685-5615. 2020.
- [8] A. S. B. Karno, W. Hastomo, Arsitektur Alexnet Convolution Neural Network (CNN) Untuk Mendeteksi Covid-19 Image Chest-Xray. Proceeding KONIK (Konferensi Nasional Ilmu Komputer) 5, pp. 482-485, 2021.
- [9] A. S. B. Karno, A. D. Wardhana, and I. S. K. E. Sally, Deteksi Covid-19 Image Chest X-Ray dengan Convolution Neural Network Efficient NET-B7. Prosiding SeNTIK 5, pp. 23-28, 2021.
- [10] H. Kaiming, and J. Sun, Convolutional neural networks at constrained time cost. Computer Science, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015.