

CONVOLUTION NEURAL NETWORK ARSITEKTUR MOBILENET-V2 UNTUK MENDETEKSI TUMOR OTAK

Widi Hastomo, Sugiyanto dan Sudjiran
STMIK Jakarta STI&K
Jl. BRI No.17, Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140
widie.has@gmail.com

ABSTRAK

Tumor ganas atau kanker adalah penyebab kematian kedua di dunia setelah kardiovaskuler. Negara berkembang tingkat kematian terhadap penyakit tumor mencapai 70%, sedangkan di negara maju tingkat kematian dapat ditekan karena peralatan dan pelayanan kesehatan sudah sangat baik. Diagnosa cepat dan lebih dini tentu akan mampu menekan tingkat kematian penyakit ini. Metoda CNN mampu membaca image dari peralatan CT Scanner untuk memprediksi pasien terhadap penyakit tumor otak. Penelitian ini menggunakan CNN dengan arsitektur MobileNet-V2 untuk mentraining dan menguji sebanyak 2.870 image tumor otak. Hasil dari penelitian ini diperoleh nilai akurasi training dan testing masing-masing sebesar 97% dan 94%. Dengan nilai akurasi untuk tiap klasifikasi yaitu glioma (99%), meningioma (85%), no_tumor (99%) dan pituaty (96%). Akurasi hasil dari penelitian ini adalah sangat baik, dan model yang dihasilkan dapat digunakan untuk mendiagnosa pasien dengan cepat, murah dan akurat.

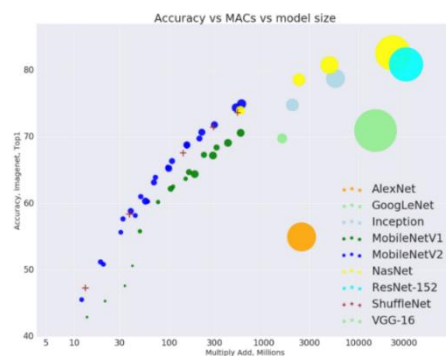
Kata Kunci : MobileNet, Deep Learning, Convolution Neural Network, Tumor Brain, CT Scan.

PENDAHULUAN

Tumor otak dibedakan menjadi dua berdasarkan pusat sebarannya. Pertama adalah tumor primer, tumor yang berasal dari jaringan otak itu sendiri. Kedua adalah tumor sekunder, tumor yang berasal dari bagian tubuh lain kemudian menyebar kebagian kepala (otak). Tumor ganas adalah jenis penyakit yang menyebabkan kematian nomor dua setelah kardiovaskuler. Statistik mencatat 1/6 kematian di dunia adalah karena penyakit tumor. Pada tahun 2018, sebanyak 9,6 juta kematian dan 70% terdapat di negara berkembang[1]. Untuk negara Indonesia kematian karena penyakit tumor berada di posisi setelah ginjal, diabetes, stroke dan darah tinggi[2].

Terlambatnya penanganan dini adalah faktor utama tingginya kematian, pertolongan yang terlambat dikarenakan pasien datang ke unit medis setelah dalam kondisi stadium tinggi. Para medis mendiagnosa tumor melalui saraf penglihatan, pendengaran dan tingkat refleksi tubuh. Untuk mengetahui jenis tumor jinak atau ganas, biasanya dengan proses pengambilan sampling jaringan sel. Peralatan radiologi *Computer Tomography Scanner* (CT scan) dan MRI dapat digunakan untuk diagnosa deteksi tumor brain[3].

Penelitian ini menggunakan image yang dihasilkan dari peralatan radiologi CT scanner. Image dengan jumlah besar ini akan digunakan sebagai data training oleh mesin learning, bertujuan memperoleh model matrik (kernel). Model ini selanjutnya dapat berguna memprediksi image baru yang belum diketahui labelnya. Metode deep learning yang digunakan adalah *Convolution Neural Network* (CNN) dengan memilih dari sekian banyak arsitektur CNN, yaitu arsitektur MobileNet versi 2. Arsitektur ini dipilih selain dapat menghasilkan akurasi tinggi juga ringan dan mampu berjalan di atas komputer dengan performansi yang tidak tidak terlalu tinggi (personal computer atau laptop) (Gambar 1).




Gambar 1. Perbandingan akurasi arsitektur CNN [4]

Masih banyak jenis tumor yang belum diketahui karena lokasi tumor sangat sulit dijangkau. Jenis tumor otak dibedakan menjadi 2 yaitu glioma dan non glioma. Glioma adalah jenis tumor yang tumbuh dari sel pendukung otak (glial), dan non glial tumbuh di luar sel pendukung otak. Jenis non glial dibedakan lagi menjadi jenis tumor tumbuh lambat (meningioma) dan tumor yang mengekresi hormon (pituitary)[5].

METODE PENELITIAN


Dalam penelitian ini dipergunakan dataset 2.870image[6]. Setiap image di klasifikasikan ke dalam 4 kelas[7]dengan jumlah dataset tiap kelas yaitu:(Gambar 2):

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 2. Pie dan histogram dataset


Peralatan CT Scanner mampu menampilkan objek-objek yang ada di dalam kepala manusia (Gambar 3).



Gambar 3. Dataset Image Tumor Brain


Arsitektur MobileNets-V2 dirancang untuk aplikasi mobile, juga merupakan komputer menggunakan library tensorflow [8]–[11] (Gambar 4). MobileNet-V2 merupakan pengembangan dari versi-versi sebelumnya, menggunakan teknik konvolusi kedalaman terpisah atau *depthwise separable convolution* (DSP).

Tujuannya adalah menghasilkan jaringan *neural network* yang ringan dengan cara mengurangi parameter[12]–[15]. Perbedaan yang ada pada MobileNet-V2 dibandingkan dengan versi sebelumnya adalah penambahan fitur *bottleneck* dan *shortcut connection*.(Gambar 5).



Gambar 4. Arsitektur MobileNet-V2

Shortcut bottleneck input dan output untuk mengenkapsulasi lapisan bagian dalam, berfungsi merubah konsep dari rendah menjadi tinggi. Shortcut ini menjadikan training lebih cepat dan akurasi lebih tinggi[7].



Gambar 5. Block konvolusi linear bottleneck[16]

Terdapat dua operasi di dalam MobileNet yaitu Depthwise Convolution (DW) dan Pointwise Convolution (PW)[17]. DW adalah lapisan pertama didalam shortcut, merupakan filter ringan dengan menerapkan filter konvolusi tunggal di setiap input channel[18]–[20]. Lapisan DW menggunakan stride antara 1 dan 2, dipergunakan secara bergantian. PW adalah lapisan kedua berupa konvolusi 1 x 1, untuk membentuk feature baru melalui penghitungan kombinasi linear. (Gambar 6)

Type / Stride	Filter Shape	Input Size
Conv / s2	3 × 3 × 3 × 32	224 × 224 × 3
Conv dw / s1	3 × 3 × 32 dw	112 × 112 × 32
Conv / s1	1 × 1 × 32 × 64	112 × 112 × 32
Conv dw / s2	3 × 3 × 64 dw	112 × 112 × 64
Conv / s1	1 × 1 × 64 × 128	56 × 56 × 64
Conv dw / s1	3 × 3 × 128 dw	56 × 56 × 128
Conv / s1	1 × 1 × 128 × 128	56 × 56 × 128
Conv dw / s2	3 × 3 × 128 dw	56 × 56 × 128
Conv / s1	1 × 1 × 128 × 256	28 × 28 × 128
Conv dw / s1	3 × 3 × 256 dw	28 × 28 × 256
Conv / s1	1 × 1 × 256 × 256	28 × 28 × 256
Conv dw / s2	3 × 3 × 256 dw	28 × 28 × 256
Conv / s1	1 × 1 × 256 × 512	14 × 14 × 256
5× Conv dw / s1	3 × 3 × 512 dw	14 × 14 × 512
Conv / s1	1 × 1 × 512 × 512	14 × 14 × 512
Conv dw / s2	3 × 3 × 512 dw	14 × 14 × 512
Conv / s1	1 × 1 × 512 × 1024	7 × 7 × 512
Conv dw / s2	3 × 3 × 1024 dw	7 × 7 × 1024
Conv / s1	1 × 1 × 1024 × 1024	7 × 7 × 1024
Avg Pool / s1	Pool 7 × 7	7 × 7 × 1024
FC / s1	1024 × 1000	1 × 1 × 1024
Softmax / s1	Classifier	1 × 1 × 1000

Gambar 6. Layer MobileNet-V2[17]


HASIL DAN PEMBAHASAN

Hasil training dari dataset sebanyak 2.870 image dan epoch 100 menghasilkan nilai akurasi 97% (Gambar 7-9).


```

steps_per_epoch = train_generator.samples // train_generator.batch_size
validation_steps = valid_generator.samples // valid_generator.batch_size
hist = model.fit(
    train_generator,
    epochs=epochs, steps_per_epoch=steps_per_epoch,
    validation_data=validation_generator,
    validation_steps=validation_steps, history)
0.8300
Epoch 95/100
71/71 [-----] - 61s 860ms/step - loss: 0.4836 - accuracy: 0.9568 - val_loss: 0.7898 - val_accuracy:
0.8206
Epoch 96/100
71/71 [-----] - 61s 860ms/step - loss: 0.4891 - accuracy: 0.9568 - val_loss: 0.7815 - val_accuracy:
0.8364
Epoch 97/100
71/71 [-----] - 61s 860ms/step - loss: 0.4789 - accuracy: 0.9608 - val_loss: 0.7216 - val_accuracy:
0.8415
Epoch 98/100
71/71 [-----] - 61s 860ms/step - loss: 0.4792 - accuracy: 0.9543 - val_loss: 0.7398 - val_accuracy:
0.8206
Epoch 99/100
71/71 [-----] - 61s 862ms/step - loss: 0.4853 - accuracy: 0.9536 - val_loss: 0.7388 - val_accuracy:
0.8272
Epoch 100/100
71/71 [-----] - 61s 860ms/step - loss: 0.4726 - accuracy: 0.9604 - val_loss: 0.7225 - val_accuracy:
0.8456
    
```

Gambar 7. Akurasi training 97%



Gambar 8. Grafik akurasi training dan testing



Gambar 9. Grafik Loss Value training dan testing

Pengujian (testing) dilakukan menggunakan dataset input secara keseluruhan (100%), jumlah 2.870 image tumor brain, terdiri dari Glioma (826), Meningioma (822), No_tumor (395), Pituitary (827). Hasil pengujian komputer diperoleh nilai akurasi secara keseluruhan adalah 94%, dengan uraian akurasi setiap kelas adalah glioma (99%), meningioma (85%), no_tumor (99%) dan pituitary (96%). Pengukuran (metric) menggunakan library sklearn dan seaborn yang tersedia di tensor flow, hasil perhitungan dengan visualisasi seperti pada Gambar 10-11.


```

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)
    
```

0.937979094076655

```

array([[709, 110,  0,  7],
       [ 5, 792,  0, 25],
       [ 0,  7, 387,  1],
       [ 0, 21,  2, 804]], dtype=int64)
    
```



Gambar 10. 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      0.99      0.86      0.92      826
 meningioma_tumor  0.85      0.96      0.90      822
 no_tumor          0.99      0.98      0.99      395
 pituitary_tumor   0.96      0.97      0.97      827

 accuracy                   0.94      2870
```

Gambar 11. Report Klasifikasi

Hasil pengukuran akurasi, presisi, Recall dan f1-score (Gambar 11), dapat diperjelas dalam bentuk tabel 1, sebagai berikut :

Tabel 1. Penjelasan report klasifikasi

Glioma	A
Meningoma	B
No_tumor	C
Pituatary	D

		Sebenarnya				
		A	B	C	D	Support
Pred	A	709	110	0	7	826
	B	5	792	0	25	822
	C	0	7	387	1	395
	D	0	21	2	804	827
		714	930	389	837	2870

	Precision	Recall	f1-score
A	709/714= 0.99	709/826= 0.86	2*709/(714+826) = 0.92
B	792/930= 0.85	792/822= 0.96	2*792/(930+822) = 0.90
C	387/389= 0.99	387/395= 0.98	2*387/(389+395) = 0.99
D	804/837= 0.96	804/827= 0.97	2*804/(837+827) = 0.97

Accuracy = (709+792+387+804)/2870 = 0.94

PENUTUP

- Penelitian ini telah berhasil melakukan training dan testing data dari 2.870 image tumor brain, dengan akurasi training sebesar 97% dan akurasi testing 94%.
- Karena nilai akurasi sangat baik, model dapat dipergunakan untuk memprediksi image tumor brain dengan label yang belum diketahui.
- Masih sangat terbuka untuk dilakukan penelitian lain dengan arsitektur yang berbeda untuk memperoleh nilai akurasi yang lebih tinggi lagi.
- Artificial intelligence (CNN deep learning) dapat membantu meringankan tenaga medis agar dapat melayani dan mendiagnosa lebih cepat dan tepat pasien penderita tumor brain.

DAFTAR PUSTAKA

[1] Kemenkes RI, Profil Kesehatan Indonesia 2018, vol. 40, no. 5. 1987.

[2] Kemkes.go.id, “Hipertensi Penyakit Paling Banyak Diidap Masyarakat,” 2019.

[3] A. N. J. Kadry, S., Rajinikanth, V., Raja, N. S. M., Hemanth, D. J., Hannon, N. M., & Raj, “Evaluation of brain tumor using brain MRI with modified-moth-flame algorithm and Kapur’s thresholding: a study,” *Evol. Intell.*, vol. 14, no. 2, pp. 1053–1063, 2021.

[4] Samuel Marks, “Tensorflow Model,” Github, 2020. [Online]. Available: <https://github.com/tensorflow/models/tree/master/research/slim/nets/mobilenet>.

[5] R. Chen, Y., Kim, J., Yang, S., Wang, H., Wu, C. J., Sugimoto, H., ... & Kalluri, “Type I collagen deletion in α SMA+ myofibroblasts augments immune suppression and accelerates progression of pancreatic cancer,” *Cancer Cell*, vol. 39, no. 4, pp. 548–565, 2021.

[6] P. Raikote, “Brain Tumor Features (Extracted),” kaggle.com, 2020. [Online]. Available: <https://www.kaggle.com/pranavraikote/braintumorfeaturesextracted/task?taskId=643>.

[7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018.

[8] W. Hastomo and A. Satyo, “Long Short Term Memory Machine Learning Untuk Memprediksi Akurasi Nilai Tukar IDR Terhadap USD,” vol. 3, 2019.

[9] W. Hastomo and A. Satyo, “Kemampuan Long Short Term Memory Machine,” vol. 4, no. September, pp. 229–236, 2020.

[10] A. S. B. Karno, W. Hastomo, and I. S. K. Wardhana, “Prediksi Jangka Panjang Covid-19 Indonesia Menggunakan Deep Learning Long-Term,” *Semin. Nas. Teknol. Inf. dan Komun.*, pp. 483–490, 2020.

- [11] W. Karno, A. S. B., & Hastomo, "Optimalisasi Data Terbatas Prediksi Jangka Panjang Covid-19 Dengan Kombinasi Lstm Dan GRU," *Pros. SeNTIK*, vol. 4, no. September, pp. 181–191, 2020.
- [12] L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Simulated Annealing Algorithm for Deep Learning," *Procedia Comput. Sci.*, vol. 72, pp. 137–144, 2015.
- [13] V. Ayumi, L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Optimization of convolutional neural network using microcanonical annealing algorithm," *2016 Int. Conf. Adv. Comput. Sci. Inf. Syst. ICACSYS 2016*, pp. 506–511, 2017.
- [14] L. M. Rasdi Rere, M. I. Fanany, and A. M. Arymurthy, "Metaheuristic Algorithms for Convolution Neural Network," *Comput. Intell. Neurosci.*, vol. 2016, 2016.
- [15] L. M. R. Rere, R. Dalam, and K. Baru, "Studi Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network," vol. 3, 2019.
- [16] R. O. Ekoputris, "MobileNet: Deteksi Objek pada Platform Mobile," *Medium Toward Data Science*, 2018. [Online]. Available: <https://medium.com/nodeflux/mobile-net-deteksi-objek-pada-platform-mobile-bbbf3806e4b3>. [Accessed: 20-Jun-2021].
- [17] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017.
- [18] A. S. B. Karno, W. Hastomo, & Arif, D., and E. S. Moreta, "Optimasi Portofolio Dan Prediksi Cryptocurrency Menggunakan Deep Learning Dalam Bahasa Python," vol. 4, no. September, 2020.
- [19] W. Hastomo, "Gesture Recognition For Pencak Silat Tapak Suci Real-Time Animation," vol. 2, pp. 91–102, 2020.
- [20] W. Hastomo, A. S. Bayangkari Karno, N. Kalbuana, A. Meiriki, and Sutarno, "Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia," *J. Phys. Conf. Ser.*, vol. 1933, no. 1, p. 012050, 2021.