

Algoritma *Convolutional Neural Network* sebagai Alat Bantu Analisa Tingkat Keparahan Tumor Otak

IRMANIAR^{1,2}, JOSUA TIMOTIUS MANIK¹, FREDDY HARYANTO²

¹Program Studi Fisika, Universitas Matana, Tangerang, Indonesia

²Program Studi Fisika, Institut Teknologi Bandung, Bandung, Indonesia

Email: niarirmaniar@gmail.com

Received 31 Juli 2023 | *Revised* 30 Oktober 2023 | *Accepted* 22 Januari 2024

ABSTRAK

Kecerdasan buatan telah menjadi dasar dalam pengembangan computer-aided-diagnosed (CAD), yaitu alat tambahan yang digunakan untuk melakukan diagnosa penyakit, misalnya tumor otak. Pada penelitian ini dilakukan klasifikasi otomatis citra MRI otak ke dalam 4 kategori, yaitu tumor otak grade II, III, IV dan non-tumor menggunakan Convolutional Neural Network (CNN). Tiga jenis arsitektur yang digunakan, yaitu arsitektur 12 lapisan, Resnet-152 dan VGG-16. Performa ketiga arsitektur terhadap data asli dan data yang mengalami augmentasi dibandingkan hasilnya. Augmentasi dilakukan dengan 6 teknik. Hasilnya menunjukkan bahwa ketiga model dapat melakukan klasifikasi tumor dengan akurasi masing-masing sebesar 84%, 95% dan 84% pada data tanpa augmentasi dan 49%, 81% dan 72% untuk data yang mengalami augmentasi. Hasil tersebut menunjukkan bahwa arsitektur Resnet-152 memberikan performa terbaik dibandingkan dengan arsitektur lainnya.

Kata kunci: Tumor otak, Convolutional Neural Network (CNN), Resnet-152, VGG-16

ABSTRACT

Artificial intelligence has become the basis for the development of computer-aided-diagnosed (CAD), an additional tool used to diagnose diseases, such as brain tumors. In this study, automatic classification of brain tumor was carried out into 4 categories, namely grade II, III, IV and non-tumor using the Convolutional Neural Network (CNN) algorithm. Three types of architecture are used, namely 12 layer architecture, Resnet-152 and VGG-16. Performance of three architectures using non-augmentation data and using augmentation data is compared. The augmentation is done using six techniques. The results show that the three models can classify tumors with an accuracy of 84%, 95% and 84% respectively for data without augmentation and 49%, 81% and 72% for data with augmentation. It can be concluded that the Resnet-152 architecture provides the best performance than the other architectures.

Keywords: Brain tumor, Convolutional Neural Network (CNN), Resnet-152

1. PENDAHULUAN

Kecerdasan buatan telah mengalami perkembangan yang sangat signifikan dalam dua dekade terakhir, terutama ketika era *smartphone* mulai berkembang di awal 2011. Perkembangannya telah memasuki hampir semua bidang, mulai dari pendidikan, keuangan, keamanan, transportasi hingga kesehatan. Dalam bidang kesehatan, kecerdasan buatan telah menjadi dasar dalam pengembangan *computer-aided-diagnosed* (CAD), yaitu sebuah alat bantu berbasis komputer yang menggunakan metode *machine learning* untuk menganalisa data berupa gambar maupun non-gambar dan melakukan prediksi diagnosa terhadap data tersebut. Prediksi dari CAD digunakan sebagai alat bantu bagi para dokter dan radiologis dalam memberikan diagnosa dari pemeriksaan yang dilakukan (**Chan et al., 2020**). *Computer-aided-diagnosed* (CAD) saat ini dianggap sebagai alat tambahan yang penting karena dapat mengurangi kesalahan manusia dan waktu dalam melakukan diagnosa, terutama untuk penyakit-penyakit berbahaya dan mematikan seperti kanker atau tumor ganas.

Salah satu jenis tumor yang sangat berbahaya adalah tumor otak. Tumor ganas atau kanker otak menempati urutan kedua dari jenis kanker yang bersifat mematikan. Secara umum, ada 4 tingkat keparahan tumor otak, yaitu tumor otak *grade* I, II, III dan IV. Tumor otak *grade* I dan II digolongkan ke dalam tumor jinak, sementara tumor otak *grade* III dan IV digolongkan ke dalam tumor ganas atau kanker. Semakin tinggi *grade* atau tingkat keparahan tumor otak, maka semakin sulit kanker tersebut disembuhkan. Oleh karena itu, ketepatan diagnosa sangat penting agar dapat memberikan pengobatan yang tepat sesuai dengan tingkat keparahannya (**Edge & Compton, 2010**).

Sayangnya tumor otak memiliki banyak sekali jenisnya. Menurut klasifikasi WHO tahun 2016, ada lebih dari 120 jenis tumor otak (**Louis et al., 2016**), sehingga dalam menegakkan diagnosa terhadap tumor otak ini diperlukan ketelitian yang tinggi, keahlian dan juga pengalaman yang cukup untuk dapat mengidentifikasi tumor yang terbentuk. Berdasarkan hal ini, CAD dianggap mampu menjawab tantangan tersebut.

Sistem CAD untuk melakukan diagnosa tersebut umumnya menggunakan data input berupa gambar, sehingga algoritma *Convolutional Neural Network* (CNN) yang bekerja dengan memanfaatkan nilai piksel dari data citra yang digunakan dapat digunakan pada sistem CAD. CNN yang bekerja secara otomatis melakukan ekstraksi dan pemilihan fitur pada citra yang dijadikan input membuatnya menjadi algoritma yang cepat dalam melakukan klasifikasi otomatis. CNN merupakan salah satu teknik *deep learning*, yang saat ini dianggap menjadi teknik paling maju dalam klasifikasi gambar (**Xiao et al., 2019**).

Penelitian-penelitian sebelumnya telah dilakukan untuk mengembangkan algoritma yang digunakan untuk sistem CAD tumor, seperti misalnya (**Truhn et al., 2019**) yang membandingkan penggunaan CNN dan radiomik untuk mengklasifikasikan lesi payudara, (**Zukotynski et al., 2019**) yang menggunakan random forest untuk klasifikasi amyloid, (**Kumar et al., 2020**) yang menggunakan hybrid-radiomics dan stationary wavelet untuk klasifikasi glioma dan (**Alqudah et al., 2019**) serta (**Deepak & Ameer, 2019**) yang menggunakan CNN untuk klasifikasi tumor glioma, meningioma dan pituitari. Hasilnya memperlihatkan bahwa CNN memberikan perform yang lebih baik dibandingkan algoritma lainnya.

Selanjutnya, desain arsitektur CNN yang dipilih juga memainkan peranan yang sangat penting dalam menghasilkan performa CNN. Ada dua jenis arsitektur yang dapat digunakan, yaitu arsitektur yang dibangun secara khusus dan arsitektur *transfer learning*. Arsitektur

yang dibangun secara khusus artinya arsitektur tersebut dibangun secara khusus untuk menyelesaikan kasus yang hendak diselesaikan. Sementara arsitektur *transfer learning* adalah arsitektur yang sudah digunakan untuk menyelesaikan kasus tertentu dan teruji performanya, sehingga dapat digunakan untuk menyelesaikan kasus lainnya. Pada *transfer learning*, arsitektur yang digunakan sudah memiliki bobot pada tiap lapisannya. Sayangnya, tingginya performa arsitektur *transfer learning* pada kasus tertentu, belum tentu akan memberikan hasil yang sama jika digunakan untuk menyelesaikan kasus lain. Oleh karena itu, pada penelitian ini akan dibandingkan performa dari arsitektur *transfer learning* dengan arsitektur yang dibangun secara khusus untuk menyelesaikan kasus klasifikasi tumor otak. Pada arsitektur yang dibangun khusus memiliki 12 lapisan, sehingga selanjutnya disebut model 12 lapisan, sementara untuk arsitektur *transfer learning* yang digunakan adalah Resnet-152 dan VGG-16.

2. METODOLOGI

2.1. Persiapan Data

Dataset yang digunakan pada penelitian ini adalah dataset REMBRANDT dan dataset IXI yang tersedia secara bebas di internet. Dataset REMBRANDT berisi citra MRI otak bersumber dari 130 pasien yang berasal dari 2 Rumah Sakit, yaitu *Henry Ford Hospital* dan *Thomas Jefferson University Hospital*. Dataset ini sudah memiliki label, yaitu astrositoma *grade II* dan *III*; oligodendroglioma *grade II* dan *III*; dan glioblastoma multiforme. Jumlah citra tiap pasien yang digunakan adalah 5-20 gambar. Tidak ada citra untuk *grade I* dalam dataset REMBRANDT, sehingga kelompok citra tumor otak *grade I* dalam penelitian ini ditiadakan. Sementara dataset IXI berisi citra MRI otak normal yang berasal dari 3 Rumah Sakit, yaitu *Hammersmith Hospital*, *Guy's Hospital* dan *Institute of Psychiatry*. Total citra yang ada dalam dataset IXI sebanyak 619 citra, namun pada penelitian ini hanya diambil citra sebanyak 421 gambar untuk menyeimbangkan datanya dengan citra MRI otak yang memiliki tumor.

Kedua dataset memiliki sudut pandang axial dengan sekuens T2. Format citra awal yang diperoleh untuk dataset REMBRANDT adalah DICOM, sedangkan pada dataset IXI berformat nifti, sehingga format kedua dataset tersebut terlebih dahulu dikonversi menjadi berformat JPG sebelum digunakan dan disortir. Selain itu dilakukan normalisasi ukuran dan juga kontras untuk menyamakan kualitas citra yang digunakan.

Convolutional Neural Network dirancang untuk bekerja secara otomatis dan adaptif mempelajari hierarki fitur spasial, dari pola tingkat rendah hingga tingkat tinggi (**Yamasitha et al., 2018**). Semakin banyak gambar yang digunakan oleh CNN untuk mempelajari pola fitur dari suatu gambar, maka akan semakin pintar CNN dalam melakukan klasifikasi gambar. Oleh karena itu, jumlah data memainkan peran yang sangat penting terhadap performa CNN yang digunakan. Pada penelitian ini dilakukan peningkatan jumlah data dengan melakukan augmentasi, yaitu proses melakukan manipulasi satu gambar sehingga dihasilkan beberapa gambar yang seolah berbeda (**Shorten & Khoshgoftaar, 2019**).

Augmentasi yang dilakukan pada penelitian ini berupa pergeseran ke kanan dan kiri dengan rentang 10 piksel, rotasi dengan rentang 300 sampai -300, pemotongan lebar sebesar 10 piksel, pemotongan tinggi sebesar 10 piksel, pembalikan secara horizontal dan pengecilan gambar hingga menjadi 80%. Setelah itu, data tersebut dibagi ke dalam 3 folder, yaitu data latihan, data validasi dan data tes. Masing-masing folder memiliki 4 folder lagi, yaitu folder *grade II*, *III*, *IV* dan non-tumor. Hasil sebaran jumlah data pada tiap folder ditunjukkan pada Tabel 1.

Tabel 1. Sebaran Data yang Digunakan pada Tiap Kelas

Kelas <i>Grade</i> Tumor	Tanpa Augmentasi				Dengan Augmentasi			
	Latihan	Validasi	Tes	Jumlah	Latihan	Validasi	Tes	Jumlah
Grade II	487	40	40	567	2.992	240	40	3.272
Grade III	330	40	40	410	2.010	240	40	2.290
Grade IV	316	40	40	396	1.896	240	40	2.176
Normal	341	40	40	421	2.046	240	40	2.326
Jumlah	1.474	160	160	1.794	8.944	960	160	10.069

2.2. Klasifikasi Otomatis

Klasifikasi otomatis dilakukan dengan menggunakan algoritma Convolutional Neural Network (CNN), yang merupakan salah satu algoritma berbasis deep learning. CNN bekerja dengan menggunakan nilai piksel sebagai data input dari citra yang dipakai (Fitri, 2020).

Pada tahap persiapan data, setelah gambar pada tiap folder siap digunakan, maka langkah selanjutnya adalah melakukan latihan pada tiap algoritma CNN. Latihan dilakukan menggunakan data latihan untuk memberi nilai bobot pada tiap piksel gambar menggunakan fungsi aktivasi. Kemudian divalidasi menggunakan data validasi. Dalam proses latihan ini, performa yang dihasilkan sangat dipengaruhi oleh *hyperparameter* yang digunakan. Tabel 2 menunjukkan *hyperparameter* yang digunakan pada penelitian ini.

Tabel 2. Hyperparameter yang Digunakan

Parameter	Yang digunakan
<i>Epoch</i>	30
<i>Learning rate</i>	0,001
<i>Batch size</i>	128
<i>Optimizer</i>	Adam
Fungsi <i>Loss</i>	<i>Cross Entropy</i>

Setelah latihan selesai, proses selanjutnya adalah menguji model untuk membuat prediksi dengan menggunakan data tes. Hasil uji yang diperoleh kemudian dievaluasi menggunakan parameter akurasi dan *confusion matrix*.

Penelitian ini membandingkan tiga jenis arsitektur, yaitu arsitektur CNN 12 lapisan, arsitektur *Residual Neural Network* (Resnet-152) dan arsitektur *Visual Geometry Group* (VGG-16). Arsitektur 12 lapisan merupakan model yang dilatih hanya dengan data yang digunakan dalam penelitian ini, sementara Resnet-152 dan VGG-16 merupakan model *transfer learning*. *Transfer learning* artinya model tersebut telah terbukti berhasil menyelesaikan suatu permasalahan lain dan sudah memiliki bobot yang telah terlatih di setiap lapisannya sehingga dapat mengurangi waktu latih model.

Pada penelitian ini, bagian *transfer learning* dari kedua model yang digunakan hanyalah bagian *feature extraction map*, sementara bagian *Fully Connected*-nya dimodifikasi dengan menggunakan arsitektur yang sama seperti pada model 12 lapisan. Tabel 3, 4 dan 5 masing-masing menunjukkan arsitektur model 12 lapisan dan arsitektur bagian *fully connected* untuk Resnet-152 dan VGG-16.

Tabel 3. Arsitektur Model 12 Lapisan

Lapisan	Ukuran Kernel	Stride	Ukuran Output
<i>Input</i>	3x3	1	240x240
Konvolusi 1	2x2	2	240x240x32
<i>Max Pooling 1</i>	3x3	2	120x120x32
Konvolusi 2	3x 3	2	60x60x32
<i>Max Pooling 2</i>	2x2	2	30x30x32
<i>Max Pooling 3</i>	2x2	2	15x15x32
<i>Max Pooling 4</i>	-	-	8x8x32
<i>Flatten</i>	-	-	2048
<i>Dense 1</i>	-	-	100
<i>Dense 2</i>	-	-	100
<i>Dropout</i>	-	-	100
<i>Dense 3</i>	-	-	4

Tabel 4. Arsitektur *Transfer Learning* Resnet-152


Lapisan	Ukuran Output
Resnet152 (fungsional)	8x8x2048
<i>Flatten</i>	131072
<i>Dense 1</i>	1024
<i>Dense 2</i>	1024
<i>Dense 3</i>	4

Tabel 5. Arsitektur *Transfer Learning* VGG-16

Lapisan	Ukuran Output
VGG16 (fungsional)	7x7x512
<i>Flatten</i>	25088
<i>Dense 1</i>	1024
<i>Dense 2</i>	1024
<i>Dense 3</i>	4

3. HASIL DAN PEMBAHASAN

Gambar 1 merupakan contoh citra MRI untuk tiap kelas. Adanya perbedaan kontras pada citra MRI tumor otak grade II, III dan IV dengan citra MRI otak sehat atau non tumor dikarenakan adanya perbedaan *repetition time* (TR) dan *echo time* (TE) yang digunakan. Citra MRI otak dengan tumor grade II, III dan IV menggunakan TR dan TE masing-masing sebesar 2020 ms dan 80 ms, sementara pada otak non tumor menggunakan TR dan TE masing-masing sebesar 8178,34 ms dan 100 ms.



Gambar 1 (a) Tumor Otak *Grade II* (b) Tumor Otak *Grade III* (c) Tumor Otak *Grade IV* (d) Otak Sehat atau *Non-Tumor*

Berdasarkan Gambar 1 tampak bahwa pada *grade II*, *III* dan *IV* terdapat hiperintensitas di daerah tertentu pada otak yang tidak tampak pada daerah yang sama di citra MRI non tumor. Daerah peningkatan intensitas inilah yang dideteksi sebagai daerah tumor. Hiperintensitas untuk tiap *grade* tumor menunjukkan karakteristik yang berbeda-beda. Pada citra MRI dengan *grade* tumor otak yang rendah seperti yang diperlihatkan pada gambar 1a, homogenitas dari hiperintensitas yang terjadi cukup tinggi, yakni mendekati 100%. Sementara untuk citra MRI otak dengan *grade* tumor yang lebih tinggi memiliki homogenitas yang lebih rendah. Berdasarkan dokumen klinis yang disertai pada dataset, gambar 1b memiliki tingkat homogenitas 34%-67%, sedangkan gambar 1c memiliki tingkat homogenitas 6%-33%. Selain itu pada tumor otak dengan *grade* yang tinggi juga menunjukkan adanya kerusakan di daerah sekitar tumor dan penekanan tumor terhadap garis tengah otak. Tingkat homogenitas ini sulit untuk diukur secara akurat oleh mata manusia, sehingga penggunaan CNN yang bekerja dengan cara mengesktrak fitur dan pola yang ada pada citra secara otomatis melalui lapisan konvolusinya dapat dimanfaatkan sebagai alat bantu untuk melakukan klasifikasi grade tumor secara lebih akurat.

Citra atau gambar tersusun atas piksel-piksel yang memiliki nilai dalam rentang tertentu yang menunjukkan tingkat kehitaman dari piksel. Pada algoritma CNN, nilai piksel inilah yang digunakan sebagai data input. Data input tersebut mengalami proses yang berbeda dalam tiap lapisan CNN hingga menjadi vektor 1 dimensi yang digunakan sebagai data input pada jaringan saraf tiruan. Parameter yang dilatih pada tiap lapisan model CNN A, Resnet-152 dan VGG-16 masing-masing ditunjukkan pada Tabel 6 dan 7.

Tabel 6. Nilai *Input* dan *Output* serta Jumlah Parameter yang Dilatih pada Tiap Lapisan Model CNN 12 Lapisan dan Resnet-152

Model 12 Lapisan			Model Resnet-152		
Layer (type)	Output Shape	Param #	Layer (type)	Output shape	Param #
Input_3 (inputLayer)	(None, 240, 240, 3)	0	Input_3 (inputLayer)	(None, 240, 240, 3)	0
Conv2d_7 (Conv2D)	(None, 240, 240, 32)	896	Conv1_pad (zeropadding2D)	(None, 246, 246, 3)	0
Max_pooling2d_12 (Maxpooling)	(None, 120, 120, 32)	0	Conv1_conv (Conv2D)	(None, 120, 120, 64)	9472
Conv2d_8 (conv2D)	(None, 60, 60, 32)	9248	Conv1_bn (BatchNormaliza tion)	(None, 120, 120, 64)	256
Max_pooling2d_13 (MaxPooling)	(None, 30, 30, 32)	0	Conv1_relu (Activation)	(None, 120, 120, 64)	0
Max_pooling2d_14 (MaxPooling)	(None, 15, 15, 32)	0	Pool1_pad (zeropadding2D)	(None, 122, 122, 64)	0
Max_pooling2d_14 (MaxPooling)	(None, 8, 8, 32)	0	Pool1_pool (MaxPooling2D)	(None, 60, 60, 64)	0
Flatten_3 (Flatten)	(None, 2048)	0	Conv2_block1_1_conv (conv2D)	(None, 60, 60, 64)	4160
Dense_9 (dense)	(None, 100)	204900	Conv2_block1_1_bn (BatchNormaliza tion)	(None, 60, 60, 64)	256
Dense_10 (dense)	(None, 100)	10100	Conv2_block1_1_relu (Activation)	(None, 60, 60, 64)	0
Dropout_3 (dropout)	(None, 100)	0	Conv2_block1_2_conv (conv2D)	(None, 60, 60, 64)	36928
Dense_11 (dense)	(None, 4)	404	Conv2_block1_2_bn (BatchNormaliza tion)	(None, 60, 60, 64)	256
Total params : 225,548 Trainable params : 225,548 Non-trainable params : 0			Conv2_block1_2_relu (Activation)	(None, 60, 60, 64)	0
			Conv2_block1_0_conv (conv2D)	(None, 60, 60, 256)	
			Conv5_block3_o ut (activation)	(None, 8, 8, 2048)	0
			Total params : 58,370,944 Trainable params : 58,219,520 Non-trainable		

Model 12 Lapisan			Model Resnet-152		
Layer (type)	Output Shape	Param #	Layer (type)	Output shape	Param #
			params : 151,424		
			None Model : "sequential_2"		
			Layer	Output (Shape)	Param #
			Resnet 152 (functional)	(None, 8, 8, 2048)	58370944
			Flatten_2 (Flatten)	(None, 131072)	0
			Dense_6 (dense)	(None,1024)	134218752
			Dense_7 (dense)	(None,1024)	1049600
			Dense_8 (dense)	(None, 4)	4100
			Total params : 193,643,396 Trainable params : 145,272,452 Non-trainable params : 58,370,944		

Tabel 7. Nilai *Input* dan *Output* serta Jumlah Parameter yang Dilatih pada Tiap Lapisan Model VGG-16

Layer (type)	Output Shape	Param #
Input_4 (inputLayer)	(None, 240, 240, 3)	0
Block1_conv1 (Conv2D)	(None, 240, 240, 64)	1792
Block1_conv2 (Conv2D)	(None, 240, 240, 64)	36928
Block1_pool (MaxPooling2D)	(None, 120, 120, 64)	0
Block2_conv2 (Conv2D)	(None, 120, 120, 128)	147584
Block2_pool (MaxPooling2D)	(None, 60, 60, 128)	0
Block3_conv1 (Conv2D)	(None, 60, 60, 256)	295168
Block3_conv2 (Conv2D)	(None, 60, 60, 256)	590080
Block3_conv3 (Conv2D)	(None, 60, 60, 256)	590080
Block3_pool (MaxPooling2D)	(None, 30, 30, 256)	0
Block4_conv1 (Conv2D)	(None, 30, 30, 512)	1180160
Block4_conv2 (Conv2D)	(None, 30, 30, 512)	2359808
Block4_conv3 (Conv2D)	(None, 30, 30, 512)	2359808
Block4_pool (MaxPooling2D)	(None, 15, 15, 512)	0
Block5_conv1 (Conv2D)	(None, 15, 15, 512)	2359808
Block5_conv2 (Conv2D)	(None, 15, 15, 512)	2359808
Block5_conv3 (Conv2D)	(None, 15, 15, 512)	2359808
Block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0

Layer (type)	Output Shape	Param #
Total params : 14,714,688 Trainable params : 14,714,688 Non-trainable params : 0		
None Model: 'sequential_3'		
Layer (type)	Output shape	Param #
VGG16 (functional)	(None, 7, 7, 512)	14714688
Flatten_3 (Flatten)	(None, 25088)	0
Dense_9 (dense)	(None, 1024)	134218752
Dense_10 (dense)	(None, 1024)	1049600
Dense_11 (dense)	(None, 4)	4100
Total params : 41,459,524 Trainable params : 26,744,836 Non-trainable params : 14,714,688		

Ketiga model CNN yang sudah dilatih dan divalidasi tersebut kemudian diuji menggunakan data tes. Akurasi yang diperoleh dari ketiga model ditunjukkan pada Tabel 8.

Tabel 8. Akurasi yang Diperoleh pada Tiap Model CNN

Akurasi tanpa Augmentasi			Akurasi dengan Augmentasi		
12 lapisan	Resnet-152	VGG-16	12 lapisan	Resnet-152	VGG-16
84%	95%	84%	49%	81%	72%

Berdasarkan Tabel 8 terlihat bahwa model CNN dengan menggunakan data tanpa augmentasi menghasilkan akurasi yang lebih tinggi dibandingkan dengan model CNN yang menggunakan data dengan augmentasi. Hal ini menunjukkan bahwa peningkatan data tidak selalu meningkatkan performa dari model. Peningkatan data harus diikuti dengan kualitas dari data yang digunakan. Pada penelitian ini, penyebab menurunnya akurasi model saat dilakukan augmentasi dapat disebabkan oleh dua hal. Pertama, peningkatan data dengan teknik augmentasi menghasilkan gambar yang tidak valid, yaitu gambar yang dihasilkan tidak dapat dikenali sebagai gambar otak yang memiliki tumor. Kedua, peningkatan data menghasilkan variasi gambar yang terlalu banyak dan kompleks sehingga model tidak mampu menangkap polanya.

Dua jenis model yang digunakan, yaitu model 12 lapisan dan model *transfer learning* (Resnet-152 dan VGG-16) menunjukkan bahwa model dengan *transfer learning* menghasilkan performa yang lebih baik. Hal ini menunjukkan bahwa model yang sudah belajar sebelumnya dapat mengenali atau memberikan prediksi yang lebih baik dibandingkan model yang belajar hanya dari data dalam penelitian ini. Kedua model tersebut (Resnet-152 dan VGG-16) juga belajar dari data yang jauh lebih banyak dibandingkan dengan model 12 lapisan. Selanjutnya untuk model *transfer learning* sendiri, jika dibandingkan, hasil akurasi model Resnet-152 lebih tinggi jika dibandingkan dengan model VGG-16. Hal ini kemungkinan dapat disebabkan karena Resnet-152 memiliki lapisan yang lebih dalam dibandingkan dengan VGG-16.

Dalam penggunaan komputer sebagai alat bantu diagnosa penting sekali untuk memastikan tidak adanya kesalahan prediksi yang dilakukan. Oleh karena itu perlu dilakukan evaluasi kesalahan prediksi yang dilakukan oleh model yang dilatih menggunakan *confusion matrix*.

Tabel 9. *Confusion Matrix* pada Data Tanpa Augmentasi untuk Ketiga Model CNN

Grade	Model 12 lapisan				Model Resnet-152				Model VGG-16			
	II	III	IV	normal	II	III	IV	normal	II	III	IV	normal
II	39	0	1	0	39	0	1	0	34	2	4	0
III	15	23	2	0	2	38	0	0	7	32	0	0
IV	6	0	33	1	5	0	35	0	6	6	28	0
Normal	0	0	0	40	0	0	0	40	0	0	0	40

Tabel 10. *Confusion Matrix* pada Data dengan Augmentasi untuk Ketiga Model CNN

Grade	Model 12 lapisan				Model Resnet-152				Model VGG-16			
	II	III	IV	normal	II	III	IV	normal	II	III	IV	normal
II	38	0	2	0	28	9	2	0	27	10	2	1
III	37	2	1	0	6	26	3	0	38	0	0	2
IV	38	0	2	0	17	3	20	0	7	28	0	0
Normal	3	0	0	37	2	0	0	38	0	0	0	40

Tabel 9 dan 10 masing-masing adalah tabel *confusion matrix* dari model yang dilatih menggunakan data tanpa augmentasi dan data dengan augmentasi. Berdasarkan tabel tersebut terlihat bahwa citra otak normal merupakan kategori citra yang paling dapat dikenali oleh model. Hampir semua model dapat mengenali citra otak normal dengan akurasi hampir 100%. Hal ini karena citra non tumor tidak memiliki hiperintensitas, sehingga paling mudah dikenali dibandingkan dengan citra otak dengan tumor. Sementara untuk citra otak dengan tumor, kategori citra tumor otak *grade* II merupakan kategori dengan prediksi model paling banyak benar dan kategori tumor otak *grade* IV menjadi kategori citra tumor otak yang paling banyak salah diprediksi. Penyebabnya adalah citra tumor otak *grade* II memiliki data latih yang paling banyak, sementara citra tumor otak *grade* IV memiliki data latih paling sedikit.

Adanya ketidakseimbangan data juga berpengaruh terhadap kesalahan hasil prediksi. Kecenderungan kesalahan prediksi dari kategori citra tumor otak *grade* III dan IV ke dalam kategori citra tumor otak *grade* II disebabkan karena citra tumor otak *grade* II memiliki data latih terbanyak. Dalam penggunaan komputer sebagai alat bantu diagnosa, kesalahan prediksi lebih diharapkan jatuh ke dalam kategori penyakit yang lebih berbahaya. Hal ini untuk meningkatkan kewaspadaan dalam memberikan perawatan atau pengobatan. Oleh karena itu, untuk penelitian selanjutnya dapat dilakukan ketidakseimbangan data dengan kategori *grade* yang paling tinggi mempunyai data latih yang lebih banyak.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang diperoleh maka dapat disimpulkan bahwa ketiga model CNN yang digunakan sudah dapat melakukan klasifikasi dengan akurasi >80% dan Resnet-152 menjadi model CNN terbaik untuk bisa melakukan klasifikasi *grade* tumor otak baik pada data tanpa augmentasi maupun data dengan augmentasi. Menariknya,

peningkatan jumlah data menggunakan augmentasi justru menghasilkan model yang tidak dapat belajar dengan baik, sehingga akurasi model dalam melakukan klasifikasi lebih rendah dibandingkan model yang hanya belajar dari data tanpa augmentasi. Selain itu, adanya ketidakseimbangan data menyebabkan kecenderungan kesalahan prediksi jatuh pada kategori dengan data terbanyak, yaitu kategori tumor otak *grade II*.

DAFTAR RUJUKAN

- Alqudah, A. M., Alquraan, H., Qasmich, I. A., Alqudah, A. & Al-Sharu, W. (2019). Brain tumor classification using deep learning technique - a comparison between cropped, uncropped, and segmented lesion images with different sizes, *International Journal of Advanced Trends in Computer Science and Engineering*, 8, 6
- Chan, H., Hadjiiski, L. M., & Samala, R. K. (2020). Computer-aided diagnosis in the era of deep learning. *Medical Physics*, 47, 5
- Deepak, S & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, 111, 103345
- Edge, S. B. & Compton, C. C. (2010). The American joint committee on cancer: the 7th edition of the AJCC cancer staging manual and the future of TNM, *Annals of Surgical Oncology*, 17, 1471–1474
- Fitri, L A. (2020): Optimization of convolutional neural network parameters for urinary stones classification based on attenuation coefficient and dispersive X ray spectrum, Disertasi Program Doktor, Institut Teknologi Bandung, 18-24
- Kumar, R. A., Gupta, H. S., Arora, G. N., Pandian & Raman, B. (2020). CGHF: A Computational Decision Support System for Glioma Classification Using Hybrid Radiomics- and Stationary Wavelet-Based Features, *IEEE Access*, 8, 79440-79458
- Louis, D. N., Perry, A., Reifenberger, G., Deimling, A. V., Branger, D. F., Cavenee, W. K., Ohgaki, H., Wiestler, O. D., Kleihues, P. & Ellison, D. W. (2016). The 2016 world health organization classification of tumors of the central nervous system: a summary, *Acta Neuropathol*, 131(6), 803-20
- Salamon, J. and Bello, J.P. (2017). Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification, *IEEE Signal Processing Letters*, 24, 3, 279-283
- Shorten, C. & Khoshgoftaar, T.M. (2019). A survey on Image Data Augmentation for Deep Learning. *J Big Data*, 6, 60

- Truhn, D., Schrading, S., Haaburger, C., Schneider, H., Merhof, D., Kuhl, S. (2019). Radiomic versus convolutional neural networks analysis for classification of contrast-enhancing lesions at multiparametric breast MRI, *Radiology*, 00
- Xiao, M., Zhao, C., Zhu, Q., Zhang, J., Liu, H., Li, J. & Jiang, Y. (2019). An investigation of the classification accuracy of a deep learning framework-based computer-aided diagnosis system in different pathological types of breast lesions, *Journal of Thoracic Disease*, 12, 5023-5031
- Yamashita, R., Nishio, M., Do, R.K.G., Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology, *Insights Imaging*, 9(4), 611-629
- Zukotynski, K., Gaudet, V., Kuo, P. H., Adamo, S., Goubran, M., Scott, C., Bocti, C., Borrie, M., Chertkow, H., Frayne, R., Hsiung, R., Laforce, R., Noseworthy, M. D., Prato, F. S., Sahlas, D. J., Smith, E. E., Sossi, V., Thiel, A., Soucy J. P., Tardif, J. C., & Black, S. E. (2019). The Use of Random Forests to Classify Amyloid Brain PET, *Clinical Nuclear Medicine*, 44, 10