

**KLASIFIKASI TUMOR OTAK PADA CITRA MRI
MENGUNAKAN TIGA ARSITEKTUR MODEL CNN**

SKRIPSI



MUH. RIFKY PARAHIAN SOPIAN

H071181506

**PROGRAM STUDI SISTEM INFORMASI
DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR**

2023

**KLASIFIKASI TUMOR OTAK PADA CITRA MRI
MENGUNAKAN TIGA ARSITEKTUR MODEL CNN**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
pada Program Studi Sistem Informasi Departemen Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin**

MUH. RIFKY PARAHIAN SOPIAN

H071181506

**PROGRAM STUDI SISTEM INFORMASI
DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN
ALAM UNIVERSITAS HASANUDDIN**

FEBRUARI 2023

PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini

Nama : Muhammad Rifky Parahian Sopian

NIM : H071181506

Program Studi : Sistem Informasi

Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul :

KLASIFIKASI TUMOR OTAK PADA CITRA MRI MENGGUNAKAN TIGA ARSITEKTUR MODEL CNN

Adalah karya tulisan saya sendiri, bukan merupakan pengambil alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Makassar, 5 Februari 2023



Muh. Rifky Parahian Sopian

H071181506

**KLASIFIKASI TUMOR OTAK PADA CITRA MRI
MENGUNAKAN TIGA ARSITEKTUR MODEL CNN**

Disusun dan diajukan oleh :

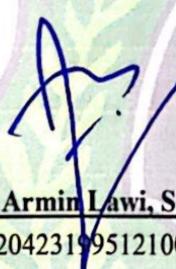
**MUH. RIFKY PARAHIAN SOPIAN
H071181506**

Telah dipertahankan dihadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian Studi Program Sarjana pada Program Studi Sistem Informasi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin dan dinyatakan telah memenuhi syarat kelulusan.

**UNIVERSITAS HASANUDDIN
Menyetujui**

Pembimbing Utama,

Pembimbing Pertama,


Dr. Eng. Armin Lawi, S.Si., M.Eng.
NIP.19720423195121001


Dr. Hendra, S.Si., M.Kom.
NIP.199102242018016001

Ketua Program Studi,




Dr. Hendra, S.Si., M.Kom.
NIP.197601022002121001

HALAMAN PENGESAHAN

Skripsi ini diajukan oleh :
Nama : Muh. Rifky Parahian Sopian
NIM : H071181506
Program Studi : Sistem Informasi
Judul Skripsi : Klasifikasi Tumor Otak Pada Citra MRI
Menggunakan Tiga Arsitektur Model
CNN

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana Komputer pada Program Studi Sistem Informasi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

DEWAN PENGUJI

Tanda Tangan

1. Ketua: Dr. Eng. Armin Lawi, S.Si., M.Eng. (.....)
2. Sekretaris: Dr. Hendra, S.Si., M.Kom. (.....)
3. Anggota: Drs. Muhammad Hasbi, M.Sc. (.....)
4. Anggota: Dr. Kasbawati, S.Si., M.Si. (.....)

Ditetapkan di : Makassar
Tanggal : 5 Februari 2023



KATA PENGANTAR

Segala puji bagi Allah *Subhanahu Wa ta'ala*, Tuhan atas langit dan bumi beserta segala isinya. Karena, berkat nikmat dan karuniaNYA sehingga penulisan skripsi ini dapat terselesaikan. Shalawat serta salam semoga senantiasa tercurahkan kepada Baginda *Rasulullah* Muhammad *Shallallahu Alaihi Wasallam* dan kepada para keluarga serta sahabat beliau, yang senantiasa menjadi teladan yang baik.

Alhamdulillah, skripsi dengan judul “Rancang Bangun Aplikasi *Mobile* Klasifikasi Kanker Kulit Dengan Pemilihan Model *Transfer Learning*” yang disusun sebagai salah satu syarat akademik untuk meraih gelar Sarjana Sains pada Program Studi Sistem Informasi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin ini dapat dirampungkan. Tentunya, dalam penulisan skripsi ini, penulis mampu melewati berbagai hambatan dan masalah berkat bantuan moril dan materil, serta dorongan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan ucapan terima kasih yang tak terhingga kepada orang tua penulis sebagai tempat kembali setelah pergi, terima kasih atas kasih sayang, doa, dan nasihat yang tulus sebagai bekal kehidupan. Rasa terima kasih juga penulis tujukan kepada saudara(i) tercinta yang telah menjadi motivator, dan rival dalam membanggakan kedua orang tua, terima kasih atas dukungan yang penulis dapatkan selama ini.

Penghargaan dan ucapan terima kasih dengan penuh ketulusan juga penulis ucapkan kepada:

1. Rektor Universitas Hasanuddin Makassar **Prof. Dr. Ir. Jamaluddin Jompa, M.Sc.**, dan seluruh Wakil Rektor dalam Lingkungan Universitas Hasanuddin.
2. Bapak Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam **Dr. Eng Amiruddin** dan para Wakil Dekan serta seluruh staf yang telah memberikan bantuan selama penulis mengikuti pendidikan di FMIPA Universitas Hasanuddin.
3. Bapak **Dr. Nurdin, S.Si. M.Si**, sebagai Ketua Departemen Matematika FMIPA Unhas. Penulis juga berterima kasih atas dedikasi dosen-dosen

pengajar, serta staf Departemen atas ilmu dan bantuan yang bermanfaat.

4. Bapak **Dr. Muhammad Hasbi, M.Sc** sebagai Ketua Program Studi Sistem Informasi Universitas Hasanuddin.
5. Bapak **Dr. Eng. Armin Lawi, S.Si., M.Eng.**, dan Bapak **Dr. Hendra, S.Si., M.Kom.** sebagai dosen pembimbing utama dan dosen pembimbing pertama atas ilmu yang beliau berikan selama proses perkuliahan, dan kesediaan beliau dalam membimbing, serta memotivasi penulis dalam penyusunan skripsi ini.
6. Bapak **Drs. Muhammad Hasbi, M.S.c.** dan Ibu **Drs. Kasbawati, S.Si., M.Si** sebagai dosen penguji pertama dan penguji kedua atas ilmu yang beliau berikan selama proses perkuliahan, dan saran serta masukan yang telah beliau berikan dalam penyusunan skripsi ini.
7. Kepada saudara(i) ku **Cecilia, Khoir, Fuad, Nasrullah, Maxi** yang telah senantiasa membantu penulis dalam penyusunan skripsi. Juga kepada saudara **Islah, Ramdan, Maxi, Luthfi, dan Ulil** yang telah menjadi *partner* tugas matakuliah mulai dari semester 1 sampai dengan semester akhir. Semangat dan motivasi juga di berikan oleh teman-teman **Sistem Informasi Unhas 2018** terimakasih atas kebersamaan, kepedulian, suka-duka, canda tawa yang telah kita lewati selama ini.
8. Kepada **kak Khaiz** yang telah meluangkan waktu dalam membagi ilmu. Terimakasih atas segala ilmu yang telah diberikan.
9. Saudara(i) ku Seperuangan Ruang Belajar (**Nasrullah, Djihad, Fuad, Ilham, Raynaldi**, serta teman-teman yang lain) terimakasih telah saling menguatkan, Semoga kesuksesan selalu kita dapatkan dalam setiap langkah-langkah kita.
10. Semua pihak yang telah memberikan bantuan kepada penulis baik berupa materi dan non materi yang tidak dapat penulis sebutkan satu per satu, terima kasih untuk bantuan dan dukungannya.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan karena keterbatasan penulis. Oleh karena itu, saran dan kritik demi penyempurnaan skripsi ini sangat penulis harapkan. Akhir kata, semoga skripsi ini membawa manfaat dan semoga Allah Subhanahu Wata'ala membalas semua kebaikan semua pihak yang

telah membantu.

Makassar, 5 Februari 2023

Muh. Rifky Parahian Sopian

PERNYATAAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS

Sebagai civitas akademik Universitas Hasanuddin, saya yang bertanda tangan di bawah ini:

Nama : Muh. Rifky Parahian Sopian
NIM : H071181506
Program Studi : Sistem Informasi
Departemen : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Hasanuddin Hak Bebas Royalti Non Eksklusif (Non-exclusive Royalty Free Right) atas karya ilmiah saya yang berjudul:

“Klasifikasi Tumor Otak Pada Citra MRI Menggunakan Tiga Arsitektur Model CNN”

beserta perangkat yang ada (jika diperlukan). Terkait dengan hal di atas, maka pihak universitas berhak menyimpan, mengalih-media/format-kan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di Makassar pada tanggal 5 Februari 2023

Yang menyatakan

Muh. Rifky Parahian Sopian

ABSTRAK

Tumor otak merupakan penyakit yang ditandai dengan pertumbuhan sel yang tidak normal pada jaringan otak. Salah satu cara yang dapat dilakukan dokter dalam pendeteksian tumor otak yaitu observasi langsung dengan diagnosis secara manual yang memiliki resiko terjadinya kesalahan. Perkembangan teknologi khususnya di bidang artificial intelligence (AI) dan machine learning berdampak besar pada bidang kedokteran yang meliputi Medical Recognition Image. Perkembangan kecerdasan buatan terhadap computer vision saat ini sudah diterapkan dalam klasifikasi citra pada bidang kesehatan. Oleh karena itu dibutuhkan sebuah metode yang dapat mengidentifikasi penyakit tumor otak dengan hasil yang optimal. Metode yang digunakan adalah Deep Learning dengan menggunakan algoritma Convolutional Neural Network (CNN) beserta arsitektur NASNetLarge, DenseNet201 dan MobileNet. Deep Learning adalah sebuah metode machine learning yang bekerja dengan cara meniru sistem kerja otak manusia, sistem ini disebut Neural Network. CNN merupakan salah satu jenis dari neural network, yang fungsi utamanya digunakan untuk data citra. Penelitian dilakukan dengan 1200 data citra penyakit tumor otak yang terbagi menjadi 4 kelas dengan masing-masing kelas memiliki 300 data citra. Dalam penelitian ini dilakukan pembagian data dengan rasio 8:2, data training sebanyak 80% dan data testing sebanyak 20%. Dari tiga arsitektur yang digunakan, model NASNetLarge mendapatkan akurasi training sebesar 95% dan akurasi validation sebesar 92%. Untuk model DenseNet201 mendapatkan akurasi training sebesar 95% dan akurasi validation sebesar 92%. Kemudian selanjutnya menggunakan model MobileNet. Hasil dari model ini lebih baik dibandingkan dua model arsitektur sebelumnya dengan mendapatkan akurasi training sebesar 96% dan akurasi validation sebesar 95%.

Kata kunci: *Convolutional Neural Network (CNN)*, *Deep Learning*, pengolahan citra, penyakit tumor otak

ABSTRACT

Brain tumor is a disease characterized by abnormal cell growth in brain tissue. One way that doctors can do in detecting brain tumors is direct observation with manual diagnosis which has a risk of error. Technological developments, especially in the field of artificial intelligence (AI) and machine learning, have had a major impact on the medical field, which includes Medical Recognition Image. The development of artificial intelligence on computer vision has now been applied in image classification in the health sector. Therefore we need a method that can identify brain tumors with optimal results. The method used is Deep Learning using the Convolutional Neural Network (CNN) algorithm along with the NASNetLarge, DenseNet201 and MobileNet architectures. Deep Learning is a machine learning method that works by imitating the working system of the human brain, this system is called a Neural Network. CNN is a type of neural network, whose main function is used for image data. The research was conducted with 1200 brain tumor image data which were divided into 4 classes with each class having 300 image data. In this study, the distribution of data was carried out with a ratio of 8: 2, 80% of the training data and 20% of the testing data. Of the three architectures used, the NASNetLarge model has a training accuracy of 95% and a validation accuracy of 92%. The DenseNet201 model has a training accuracy of 95% and a validation accuracy of 92%. Then next use the MobileNet model. The results of this model are better than the two previous architectural models by obtaining a training accuracy of 96% and a validation accuracy of 95%.

Keywords: Convolutional Neural Network (CNN), Deep Learning, image processing, brain tumor detection.

DAFTAR ISI

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS HASANUDDIN	ii
PERNYATAAN KEASLIAN.....	Error! Bookmark not defined.
LEMBAR PERSETUJUAN PEMBIMBING	Error! Bookmark not defined.
HALAMAN PENGESAHAN.....	Error! Bookmark not defined.
KATA PENGANTAR.....	vi
PERNYATAAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS.....	ix
ABSTRAK	x
ABSTRACT	xi
DAFTAR ISI.....	xii
DAFTAR GAMBAR.....	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
BAB II TINJAUAN PUSTAKA.....	4
2.1 Penelitian Terkait	4
2.2 Pencitraan MRI	5
2.5 Citra Digital.....	7
2.6 Convolutional Neural Network	8
2.7 Arsitektur Convolutional Neural Network Transfer Learning.....	14

2.8	Evaluasi Kinerja Model.....	18
BAB III METODE PENELITIAN		22
3.1	Waktu dan Tempat	22
3.2	Instrumen Penelitian.....	22
3.3	Sumber Data.....	22
3.4	Tahap Penelitian.....	23
1.	Pre-processing	23
2.	Split Data.....	24
3.	Build Model Transfer Learning	24
4.	Evaluasi model.....	24
5.	Save Model.....	25
6.	Deploy Model & Build Application.....	25
BAB IV PEMBAHASAN.....		26
4.1	Deskripsi Data.....	26
4.2	Preprocessing	26
4.3	Split Data.....	28
4.4	Augmentasi Data.....	28
4.5	Arsitektur Transfer Learning NASNetLarge, DenseNet201, dan MobileNet	29
4.6	Transfer Learning Menggunakan NASNetLarge, DenseNet201, dan MobileNet	31
4.7	Evaluasi Kinerja Model.....	38
4.8	Deployment Model NASNetLarge, DenseNet201, MobileNet	40
BAB V KESIMPULAN.....		43
5.1	Kesimpulan	43

5.2	Saran.....	43
	DAFTAR PUSTAKA.....	44
	LAMPIRAN.....	47

DAFTAR GAMBAR

Gambar 2. 1 Hasil Photo MRI Tumor Otak.....	5
Gambar 2. 2 Glioma Tumor, Meningioma Tumor, dan Pituitary Tumor	7
Gambar 2. 3 Citra Digital RGB.....	8
Gambar 2. 4 Arsitektur Convolutional Neural Network.....	9
Gambar 2. 5 Contoh Bentuk Konvolusi.....	10
Gambar 2. 6 Fungsi aktivasi ReLU.....	11
Gambar 2. 7 Fungsi aktivasi softmax.....	11
Gambar 2. 8 Ilustrasi Pooling Layer	12
Gambar 2. 9 Ilustrasi Flatten Layer.....	13
Gambar 2. 10 Sebelum Dropout (a) dan Setelah Dropout (b).....	13
Gambar 2. 11 Proses fully connected layer.....	14
Gambar 2. 12 Normal Cell dan Reduction Cell pada Arsitektur NASNetLarge ..	16
Gambar 2. 13 Arsitektur Model DenseNet201	17
Gambar 2. 14 Arsitektur Model MobileNet.....	18
Gambar 2. 15 Kurva AUC - ROC.....	21
Gambar 3. 1 Alur Penelitian.....	23
Gambar 3. 2 Ilustrasi augmentasi data	24
Gambar 4. 1 Data citra <i>grayscale</i>	26
Gambar 4. 2 Hasil <i>resize</i> citra ukuran 224×224 pixel.....	27
Gambar 4. 3 Konversi data citra menjadi <i>array</i>	27
Gambar 4. 4 Proses sebelum normalisasi data citra dan setelah normalisasi.....	28
Gambar 4. 5 Ilustrasi proses hasil augmentasi	29
Gambar 4. 6 Ringkasan arsitektur <i>NASNetLarge</i>	29
Gambar 4. 7 Ringkasan arsitektur <i>DenseNet201</i>	30
Gambar 4. 8 Ringkasan arsitektur <i>MobileNet</i>	31
Gambar 4. 9 Kurva akurasi training dan validation model <i>NASNetLarge</i>	32
Gambar 4. 10 Confusion matrix model <i>NASNetLarge</i>	32
Gambar 4. 11 Kurva ROC model <i>NASNetLarge</i>	33
Gambar 4. 12 Kurva akurasi training dan validation model <i>DenseNet201</i>	34
Gambar 4. 13 Confusion matrix model <i>DenseNet201</i>	35

Gambar 4. 14 Kurva ROC model <i>DenseNet201</i>	36
Gambar 4. 15 Kurva akurasi training dan validation model <i>MobileNet</i>	36
Gambar 4. 16 <i>Confusion Matrix</i> model <i>MobileNet</i>	37
Gambar 4. 17 Kurva ROC model <i>MobileNet</i>	38
Gambar 4. 18 Visualisasi <i>layout</i> aplikasi web	41
Gambar 4. 19 Hasil prediksi aplikasi web	42

DAFTAR TABEL

Tabel 2. 1 <i>Confusion Matrix</i>	19
Tabel 3. 1 Kelas Dataset Brain Tumor Detection	22
Tabel 4. 1 Hasil evaluasi kinerja model arsitektur NASNetLarge.....	33
Tabel 4. 2 Hasil evaluasi kinerja model arsitektur DenseNet201	35
Tabel 4. 3 Hasil evaluasi kinerja model arsitektur MobileNet.....	37
Tabel 4. 4 Evaluasi <i>precision</i> , <i>recall</i> , dan <i>f1-score</i>	39
Tabel 4. 5 Akurasi <i>Training</i> dan Akurasi <i>Validation</i>	39
Tabel 4. 6 AUC-ROC.....	40

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam satu dekade terakhir ini, dunia kesehatan mengalami perubahan atau disrupsi yang cukup besar. Perkembangan teknologi di bidang kesehatan ini akan mempermudah dokter untuk melakukan diagnosa penyakit dalam mendapatkan layanan kesehatan. Dulu, pasien yang harus mendekati diri dengan penyedia layanan kesehatan. Sekarang, penyedia layanan kesehatan yang mendekati diri ke pasien.

Tumor otak merupakan penyakit yang ditandai dengan adanya pertumbuhan jaringan abnormal di otak. Umumnya, hal ini terjadi karena sel-sel yang tumbuh secara tidak normal dan tak terkendali, yang dapat mengganggu fungsi otak. Tumor otak dapat berasal dari pertumbuhan sel abnormal di otak itu sendiri atau disebut primer. Namun, tumor otak juga dapat terjadi karena penyebaran dari kanker pada bagian lain dari tubuh atau disebut sekunder (metastasis) (sumber kutipan: www.halodoc.com/kesehatan/tumor-otak).

Magnetic Resonance Imaging (MRI) merupakan alat kedokteran yang berprinsip pada resonansi *magnetic* inti atom *hydrogen*. Dan merupakan alat diagnostik radiologi, MRI menghasilkan rekaman gambar dari tubuh atau organ manusia dengan menggunakan benda magnet. MRI diklaim sebagai alat pencitraan organ tubuh manusia dengan kualitas sangat baik, sehingga alat MRI banyak digunakan oleh para dokter (Jajang dan Riffa, 2019). Dengan mengolah citra yang dihasilkan oleh alat MRI dapat dikembangkan metode pendeteksian tumor otak yang mampu mendeteksi dan mengklasifikasikan tumor tersebut. Gambar MRI memiliki besar dampak dalam bidang analisis citra medis otomatis untuk kemampuan memberikan banyak informasi tentang struktur otak dan kelainan di dalam jaringan otak karena tingginya resolusi gambar.

Segmentasi citra tumor otak memberikan informasi yang penting bagi dokter untuk perencanaan perawatan dan evaluasi tindak lanjut. Akan tetapi segmentasi secara manual akan membutuhkan waktu yang cukup lama, sehingga segmentasi

otomatis dibutuhkan untuk menyelesaikan permasalahan waktu tersebut. Selain segmentasi otomatis diperlukan pula model yang mampu memberikan hasil klasifikasi dan analisis data. *Deep Learning* adalah bagian dari *machine learning* yang menyoroti pengembangan kerangka kerja yang dapat belajar "sendirian" tanpa dimodifikasi berulang kali oleh manusia (Bagas, 2021).

Pada penelitian ini, diajukan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan gambar MRI dari tiga jenis tumor yaitu Glioma, Meningioma, dan Pituitari. Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan *Multilayered Feedforward* (MLF) yang digunakan dalam image recognition yang mengandung dua proses dasar yang di kenal sebagai *convolution* dan *pooling*. Secara garis besar *Convolutional Neural Network* (CNN) tidak jauh beda dengan neural network biasanya. CNN terdiri dari neuron yang memiliki *weight*, bias dan activation function. Convolutional layer juga terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixels) (Putra, 2020).

Pada penelitian sebelumnya yang dilakukan oleh Jajang Sofian dan Riffa Haviani Laluma pada tahun 2019, melakukan penelitian klasifikasi tumor otak dengan menggunakan metode *image threshold* dan GLCM menggunakan algoritma K-NN (*Nearest Neighbor*). Dengan cara mengklasifikasikan tumor otak seseorang berdasarkan jenis penyakit. Dari hasil penelitian tersebut, *Data Training* dan *Data Testing* dibagi sebanyak 20 dan 10 data yang menghasilkan akurasi sebesar 83.33%, untuk MSE dan MAE masing-masing sebesar 16.6%.

Maka dari itu, penulis tertarik untuk melakukan penelitian dengan membandingkan beberapa model arsitektur CNN. Sehingga peneliti memutuskan untuk membuat penelitian yang berjudul “Klasifikasi Tumor Otak pada Citra MRI menggunakan tiga arsitektur CNN”.

1.2 Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini adalah:

1. Bagaimana mengimplementasikan model arsitektur *NASNetLarge*, *DenseNet201*, dan *MobileNet* ini pada dataset *Brain Tumor Detection*?
2. Bagaimana hasil perbandingan akurasi pengklasifikasian dari penelitian sebelumnya dan penelitian penulis menggunakan arsitektur *NASNetLarge*, *DenseNet201*, dan *MobileNet* untuk klasifikasi *Brain Tumor Detection*?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Dataset yang digunakan adalah *Brain Tumor Detection*.
2. Jenis penyakit tumor otak yang dijadikan objek penelitian adalah Glioma, Meningioma, dan Pituitari.
3. Dataset hanya menggunakan gambar citra MRI.
4. Arsitektur yang digunakan yaitu *NASNetLarge*, *DenseNet201*, dan *MobileNet*.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengimplementasi model arsitektur *NASNetLarge*, *DenseNet201* dan *MobileNet* ini pada dataset *Brain Tumor Detection*.
2. Menganalisis perbandingan hasil evaluasi kinerja model arsitektur *NASNetLarge*, *DenseNet201*, dan *MobileNet* untuk klasifikasi tumor otak pada dataset *Brain Tumor Detection*.

1.5 Manfaat Penelitian

Penelitian ini dapat menggunakan model untuk mengklasifikasi penyakit tumor otak yang menghasilkan aplikasi untuk memprediksi dan memberikan perbandingan akurasi performa dari metode *Convolutional Neural Network* (CNN).

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

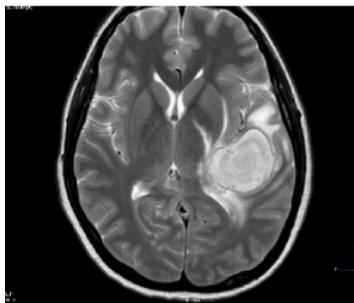
Penelitian ini merujuk pada beberapa penelitian yang telah dilakukan sebelumnya. Berikut beberapa contoh penelitian terkait:

1. Penelitian yang dilakukan oleh Redho Hidayatullah, pada tahun 2021. Pada penelitian ini berfokus pada klasifikasi citra tumor otak dengan menggunakan *deep learning*, khususnya metode *Convolutional Neural Network* (CNN) dengan arsitektur EfficientNet-B0 berdasarkan jenis penyakit tumor otak. Pengujian dilakukan dengan beberapa skenario dari *learning rate* serta kombinasi dari jumlah neuron pada dense layer. Hasil dari pengujian model tersebut mendapatkan akurasi tertinggi pada eksperimen dengan skenario *learning rate* 0.01 dan *neuron* pada dense layer berjumlah 256 gambar yang menghasilkan akurasi mencapai 99.8% dan nilai F1-score tertinggi mencapai 99.7%.
2. Penelitian yang dilakukan oleh Krisna Nuresa Qodri, Indah Soesanti, dan Hanung Adi Nugroho, pada tahun 2021, melakukan klasifikasi tumor otak citra gambar MRI dengan menggunakan arsitektur *ResNet50* dan *VGG16*. Hasil penelitian dari kedua arsitektur menunjukkan 96%. Hasil yang diperoleh menunjukkan bahwa *transfer learning* dapat menangani citra medis.
3. Penelitian yang dilakukan oleh Jajang Sofian dan Riffa Haviani Laluma pada tahun 2019, melakukan penelitian klasifikasi tumor otak dengan menggunakan metode *image threshold* dan GLCM menggunakan algoritma K-NN (*Nearest Neighbor*). Dengan cara mengklasifikasikan tumor otak seseorang berdasarkan jenis penyakit. Dari hasil penelitian tersebut, *Data Training* dan *Data Testing* dibagi sebanyak 20 dan 10 data yang menghasilkan akurasi sebesar 83.33%, untuk MSE dan MAE masing-masing sebesar 16.6%.

4. Penelitian yang dilakukan oleh Ita Arke pada tahun 2021, melakukan klasifikasi tumor otak dengan menggunakan metode CNN dan memberikan hasil klasifikasi yang baik dan akurat. Dari penelitian yang telah dilakukan, peneliti telah berhasil dalam membuat sistem klasifikasi tumor otak dengan akurasi 92,50%, presisi 98,11% dan recall 86,7%.

2.2 Pencitraan MRI

MRI adalah suatu teknik pencitraan medis dalam pemeriksaan diagnostik radiologi, yang menghasilkan rekaman citra potongan penampang tubuh atau organ manusia dengan menggunakan medan magnet dan resonansi getaran terhadap inti atom hidrogen. Teknologi ini memanfaatkan sifat atom hidrogen, dikarenakan pada sebagian besar tubuh manusia terdapat atom hidrogen. Dapat juga dikatakan bahwa MRI merupakan alat diagnostik imaging atau alat pemeriksaan radiologi berteknologi tinggi, yang menggunakan medan magnet yang besar, frekuensi radio tertentu dan seperangkat detektor dan pengolahan data untuk menghasilkan gambaran potongan-potongan anatomi tubuh manusia. Dengan pencitraan MRI dapat dihasilkan potongan atau irisan (*slice*) melintang atau tegak sesuai dengan kebutuhan (Soesanti dkk., 2011). Gambar 2.1 merupakan hasil citra dari MRI tumor otak.



Gambar 2.1 Hasil Photo MRI Tumor Otak (Sri dkk., 2018)
(sumber gambar: liputan6.com)

2.3 Tumor Otak

Tumor otak merupakan pertumbuhan jaringan abnormal yang terdapat di dalam atau di sekitar otak. Tumor otak dapat berupa jinak, tumbuh dengan lambat. Sementara lainnya ganas, disebut dengan kanker, tumbuh dengan cepat dan bersifat agresif. Hanya sekitar sepertiga dari tumor otak bersifat kanker. Tetapi kanker atau tidak, tumor otak dapat mengganggu fungsi otak jika tumbuh cukup besar untuk

menekan saraf, pembuluh darah dan jaringan di sekitarnya. Tumor yang berkembang di otak disebut tumor primer. Tumor yang menyebar ke otak setelah terbentuk di bagian tubuh yang berbeda disebut tumor sekunder atau tumor metastatik (Yudha, 2022).

Otak terbentuk dari dua jenis sel: glia dan neuron. Glia berfungsi untuk menunjang dan melindungi neuron, sedangkan neuron membawa informasi dalam bentuk pulsa listrik yang di kenal sebagai potensi aksi. Otak mengatur dan mengkoordinir sebagian besar, gerakan, perilaku dan fungsi tubuh homeostasis seperti detak jantung, tekanan darah, keseimbangan cairan tubuh dan suhu tubuh. Penelitian mengenai klasifikasi jaringan otak menggunakan MR telah dimulai sejak tahun 1977. Beberapa penelitian menggunakan MR antara lain: untuk membedakan jaringan reguler dan jaringan abnormal / tumor pada spesimen hewan percobaan, serta pemanfaatan nilai akurasi diagnostik yang diperoleh dari pencitraan MR untuk usaha mengklasifikasikan jaringan otak manusia (Lastri, 2019).

Tumor otak umumnya terdiri dari tumor otak primer dan sekunder. Tumor otak dengan kelompok primer yaitu penyakit tumor yang pertama kali tumbuh dan berkembang pada otak. Tumor ini dapat menyebar ke bagian lain dari sistem saraf, tetapi jarang tumbuh pada bagian tubuh yang lain. Sedangkan tumor otak dengan kelompok sekunder yaitu penyakit dari tumor yang bermula tumbuh pada bagian dari tubuh selain otak, kemudian meluas melalui aliran darah menuju otak. Tumor ini biasanya dikenal dengan kanker sekunder atau metastasis. Kanker yang kemungkinan menyebar ke otak yaitu melanoma, paru-paru, payudara, ginjal, dan usus (Stephen, 2007).

Penyebab terjadinya tumor adalah faktor genetik. Ada kelainan gen yang mengontrol pertumbuhan sel-sel otak. Kelainan ini dapat disebabkan oleh kelainan yang secara langsung mempengaruhi gen atau kelainan kromosom yang dapat mengubah fungsi dari gen itu sendiri. Beberapa penelitian menunjukkan bahwa paparan radiasi dan bahan kimia juga dapat meningkatkan kejadian tumor. Kemungkinan paparan bahan tersebut dapat menyebabkan perubahan struktur gen (Sri dkk., 2018).

2.4 Jenis-jenis Tumor Otak

Indra (2020) menyatakan dalam penelitiannya terkait pengklasifikasian tiga jenis tumor otak. Fokus penelitian ini adalah penyakit sebagai berikut:

1. Glioma Tumor

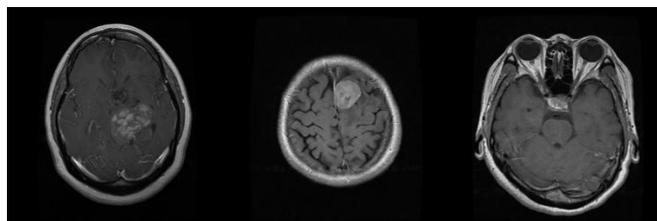
Glioma merupakan tumor otak maligna yang berasal dari sel glial. Beberapa jenis glioma adalah astrositoma, oligodendroglioma, astrositoma anaplastik, dan glioblastoma. Gejala yang timbul pada pasien glioma dapat berupa nyeri kepala hebat yang disertai muntah proyektil akibat peningkatan tekanan intrakranial, defisit neurologis progresif, kejang, dan gangguan kognitif.

2. Meningioma Tumor

Meningioma merupakan tumor otak jinak yang paling sering ditemukan. Tumor ini berasal dari sel arachnoid cap duramater. Ukuran tumor meningioma bertambah secara lambat. Lokasi meningioma dapat terletak pada basis kranial, lekukan dura, pleksus khoroid, dan juga spinal.

3. Pituitari Tumor

Pituitari merupakan sel abnormal yang membentuk massa pada kelenjar pituituari (hipofisis) di otak. Kelenjar ini bertanggung jawab untuk mengatur keseimbangan berbagai hormon pada tubuh Anda. Perasaan yang muncul karena suatu objek yang menjijikan, tidak disukai, atau dibenci. Gambar 2.2 merupakan gambar jenis penyakit tumor otak melalui hasil citra MRI.

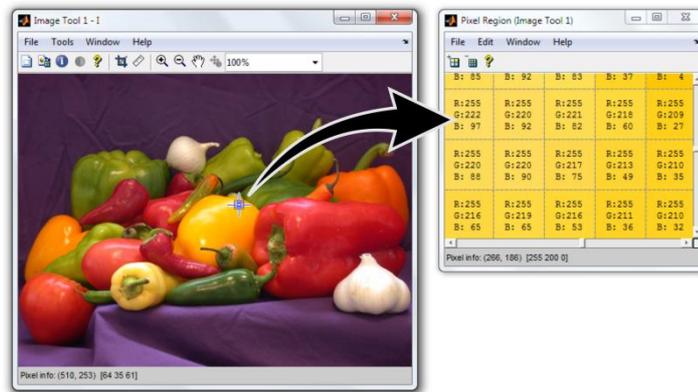


Gambar 2.2 Glioma Tumor, Meningioma Tumor, dan Pituitary Tumor
(sumber gambar: Navoneel Chakrabarty)

2.5 Citra Digital

Citra digital merupakan representasi dari fungsi intensitas cahaya dalam bentuk diskrit pada bidang dua dimensi. Citra tersusun oleh sekumpulan piksel (*picture element*) yang memiliki koordinat (x,y) dan amplitudo $f(x,y)$. Koordinat (x,y)

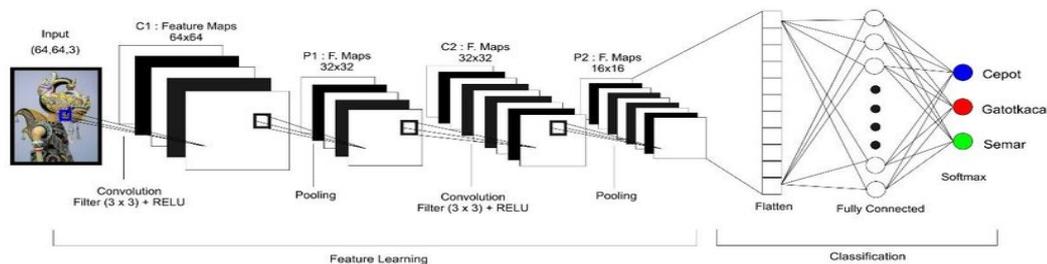
menunjukkan letak/posisi piksel dalam suatu citra, sedangkan amplitudo $f(x,y)$ menunjukkan nilai intensitas warna citra. Terdapat beberapa macam citra, salah satunya citra RGB. Citra RGB atau *Red*, *Green*, dan *Blue* merupakan sebuah citra berwarna yang memiliki masing-masing *pixel* tertentu. Jika tiap warna memiliki rentang nilai $[0, 255]$ maka terdapat tiga matriks dengan masing-masing rentang nilai yang sama sehingga totalnya adalah 2553. Seperti yang ditunjukkan pada gambar 2.3.



Gambar 2.3 Citra Digital RGB
(Sumber gambar : pemrogramanmatlab.com)

2.6 Convolutional Neural Network

Convolutional Neural Network merupakan salah satu algoritma dari *Deep Learning* yang merupakan pengembangan dari *Multi Layer Perceptron* (MLP) yang didesain untuk mengolah data dalam bentuk *grid* yang salah satunya berupa citra dua dimensi, seperti sebuah gambar atau suara. *Convolutional Neural Network* digunakan untuk mengklasifikasikan data berlabel menggunakan metode *supervised learning*, dimana cara kerja *supervised learning* adalah ada data yang dilatih dan ada variabel sasaran sehingga tujuan dari metode ini adalah untuk mengelompokkan data menjadi data yang sudah ada. CNN sering digunakan untuk mengenali objek atau pemandangan, dan melakukan deteksi dan segmentasi objek (Furi, 2018).



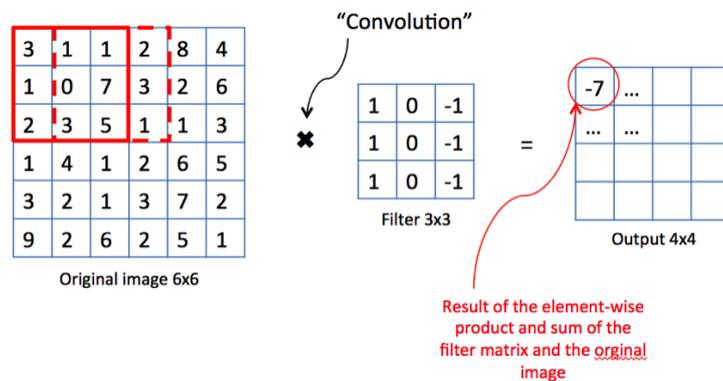
Gambar 2.4 Arsitektur *Convolutional Neural Network*
(Sumber gambar : Nurhikmat Triano)

Berdasarkan gambar 2.4, Convolutional Neural Network (CNN) didasarkan pada konvolusi gambar, dan mendeteksi fitur berdasarkan filter yang dipelajari oleh CNN melalui pelatihan. Misalnya, ketika filter yang diterapkan tidak diketahui, seperti filter untuk mendeteksi tepi atau untuk menghilangkan Gaussian noise, tetapi melalui pelatihan CNN, algoritma mempelajari filter pemrosesan gambar sendiri yang mungkin sangat berbeda dari filter pemrosesan gambar biasa. Untuk Supervised Learning, filter dipelajari sedemikian rupa sehingga fungsi bobot keseluruhan dikurangi sebanyak mungkin. Umumnya, lapisan konvolusi pertama belajar untuk mendeteksi tepi, sedangkan yang kedua dapat belajar untuk mendeteksi bentuk yang lebih kompleks yang dapat dibentuk dengan menggabungkan tepi yang berbeda, seperti lingkaran dan persegi panjang, dan sebagainya. Lapisan ketiga dan seterusnya mempelajari fitur yang jauh lebih rumit berdasarkan fitur yang dihasilkan di lapisan sebelumnya (El-Amir & Hamdy, 2020).

2.6.1 Convolutional Layer

Convolution layer adalah blok utama di dalam CNN yang terdiri dari beragam filter yang di inisial secara acak untuk melakukan operasi konvolusi yang berfungsi sebagai ekstraksi fitur untuk mempelajari representasi fitur dari suatu input gambar. Pada *convolution layer*, neuron tersusun menjadi *feature maps*. Setiap neuron pada *feature map* sebagai *receptive field*, terhubung pada neuron dari *convolution layer* sebelumnya melalui serangkaian bobot yang dilatih, biasa juga disebut dengan *filter bank* (Lecun dkk., 2015). Terdapat parameter yang dapat diubah untuk memodifikasi sifat tiap lapisan, yaitu ukuran *filter*, *stride* dan *padding*. *Stride* mengontrol bagaimana *filter* diterapkan pada data *input* dengan bergerak

sepanjang ukuran piksel yang telah ditentukan. *Padding* adalah penambahan ukuran piksel dengan nilai tertentu disekitar data input agar hasil dari bidang reseptif tidak terlalu kecil sehingga tidak banyak informasi yang hilang. Nilai ini biasanya nol sehingga disebut dengan *zero padding*. Langkah ini melibatkan menggeser filter matriks (katakanlah ukuran 3×3) di atas gambar *input* yang berukuran lebar gambar x tinggi gambar. *Filter* pertama ditempatkan pada matriks gambar dan kemudian menghitung perkalian elemen antara *filter* dan bagian gambar, diikuti dengan penjumlahan untuk memberikan nilai fitur (Bahuleyan, 2018)



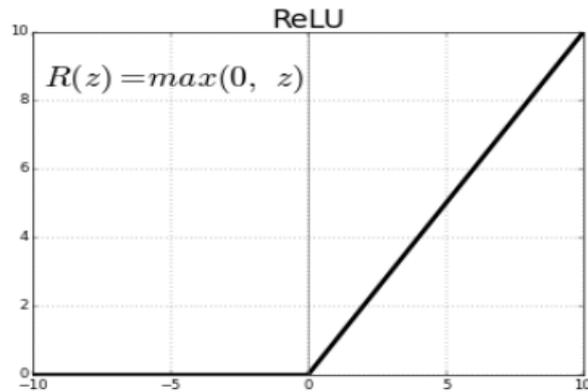
Gambar 2.5 Contoh Bentuk Konvolusi
(Sumber gambar : Michele Cavaioni)

Seperti pada gambar 2.5 nantinya citra input akan terbentuk sebuah matriks 3×3 yang bergeser sesuai dengan *stride* yang sudah ditentukan. Kemudian matriks yang terbentuk akan dilakukan kuantisasi pada filter. Hasil dari kuantisasi matriks berupa satu nilai *output*. Nantinya *output* kuantisasi dari tiap matriks pada citra akan membentuk sebuah matriks yang merupakan hasil dari konvolusi

2.6.2 Fungsi Aktivasi

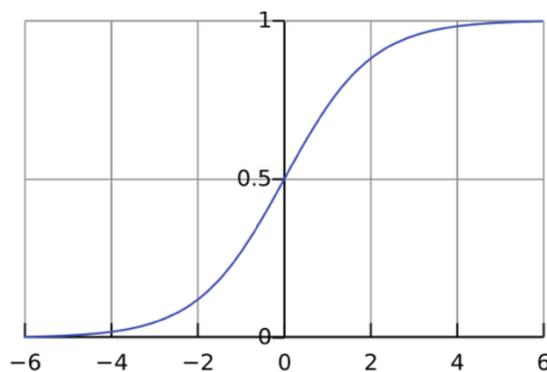
Operasi konvolusi adalah linier dan untuk membuat jaringan saraf lebih kuat, perlu untuk memperkenalkan beberapa *non-linier*. Untuk tujuan ini, dapat mengimplementasikan fungsi aktivasi seperti ReLU (Bahuleyan, 2018). *Rectified linear unit* (ReLU) merupakan salah satu fungsi aktivasi yang sering digunakan pada *convolutional neural network* (Chen dkk., 2018). Fungsi ReLU biasanya

digunakan dalam jaringan saraf untuk membantu membangun model yang berfungsi. Gambar 2.6 menunjukkan fungsi aktivasi ReLU.



Gambar 2.6 Fungsi aktivasi ReLU
(Sumber gambar : Cristiano Roberto., dkk)

Fungsi aktivasi ReLU digunakan pada proses ekstraksi fitur, tetapi pada proses klasifikasi fungsi aktivasi yang digunakan adalah *softmax*. Fungsi *Softmax* menghitung probabilitas dari setiap kelas target atas semua kelas target yang memungkinkan dan akan membantu untuk menentukan kelas target untuk input yang diberikan.

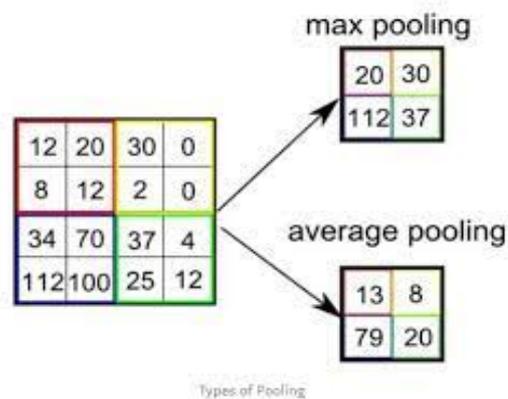


Gambar 2.7 Fungsi aktivasi *softmax*
(Sumber gambar : Claude Morag)

Seperti pada gambar 2.6 dan 2.7 perbedaan fungsi aktivasi *softmax* dan relu yaitu pada output yang dihasilkan. Pada fungsi aktivasi *relu* output yang dihasilkan adalah 0 sampai ∞ . Sedangkan fungsi aktivasi *softmax* output yang dihasilkan adalah 0 sampai 1.

2.6.3 Pooling Layer

Pooling Layer merupakan lapisan yang menggunakan fungsi dengan *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. *Pooling layer* pada model CNN biasanya disisipkan secara teratur setelah beberapa *convolution layer*. *Pooling layer* yang dimasukkan di antara lapisan konvolusi secara berturut-turut dalam arsitektur model *Convolutional Neural Network* dapat secara progresif mengurangi ukuran volume output pada *feature map*, sehingga jumlah parameter dan perhitungan di jaringan berkurang, serta untuk mengendalikan *overfitting*. Ilustrasi *Pooling Layer* ditunjukkan pada gambar 2.8.

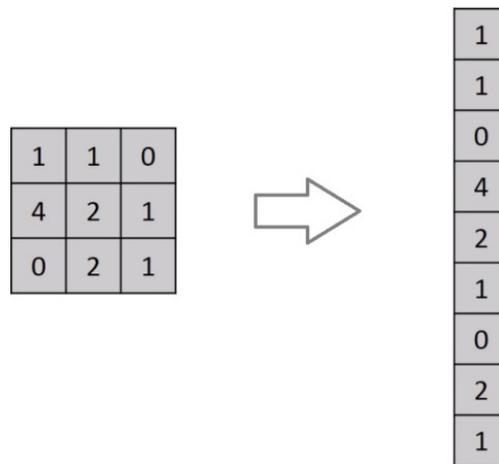


Gambar 2.8 Ilustrasi *Pooling Layer*
(Sumber gambar : Cameron Buckner)

Terdapat dua operasi *pooling*. Pada proses *pooling* nantinya hasil dari proses konvolusi akan terbentuk sebuah matriks 2x2. Nantinya tiap matriks tersebut akan diubah menjadi satu elemen matriks saja.

2.6.4 Flatten

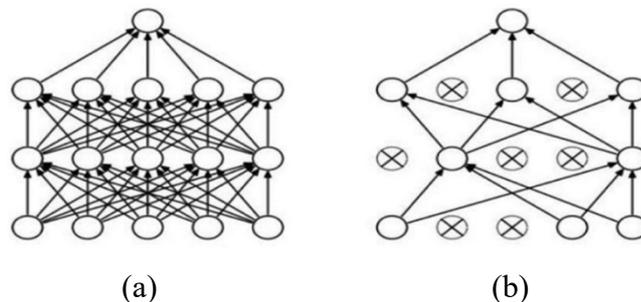
Flatten layer adalah metode untuk membuat input yang memiliki banyak dimensi menjadi satu dimensi. Proses perataan dilakukan agar keluaran dari ekstraksi ciri dapat diproses oleh *fully connected layer*. Output dari *flatten* akan menjadi input pada *fully connected layer*. Pada gambar 2.9 matriks ukuran 3x3 diubah menjadi sebuah vektor ukuran 9.



Gambar 2.9 Ilustrasi *Flatten Layer*
(Sumber gambar : superdatascience.com)

2.6.5 Dropout

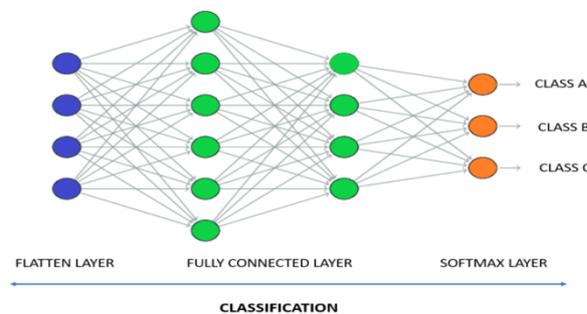
Dropout adalah teknik regularisasi jaringan syaraf dimana beberapa neuron akan dipilih secara acak dan tidak dipakai selama pelatihan. Neuron-neuron ini dapat dibuang secara acak. Hal ini berarti bahwa kontribusi neuron yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan backpropagation. Pada Gambar 2.10 ditunjukkan gambaran cara kerja *dropout* pada arsitektur CNN saat proses *training* berlangsung (Gosh dkk, 2020). *Dropout* merupakan salah satu usaha untuk *mencegah* terjadinya *overfitting* dan juga mempercepat proses learning (Santoso dan Ariyanto, 2018). Berikut adalah proses sebelum dan sesudah *dropout* dari gambar 2.10.



Gambar 2.10 Sebelum *Dropout* (a) dan Setelah *Dropout* (b)
(Sumber gambar : indiantechwarrior.com)

2.6.6 Fully Connected Layer

Fully-Connected layer adalah lapisan di mana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan syaraf tiruan biasa. *Fully connected layer* mengambil *input* dari hasil *output pooling layer* yang berupa *feature map*. *Feature map* tersebut masih berbentuk *multidimensional array* maka lapisan ini akan melakukan *reshape feature map* dan menghasilkan vektor sebanyak *n*-dimensi dimana *n* adalah jumlah kelas *output* yang harus dipilih program. Misalnya lapisan terdiri dari 500 neuron, maka akan diterapkan sebagai klasifikasi akhir dari jaringan (Dutt dan Dutt, 2017).



Gambar 2.11 Proses *fully connected layer*
(Sumber gambar : indiantechwarrior.com)

Pada gambar 2.11 *fully connected layer* terdapat tiga bagian. Pertama input layer yang merupakan output dari *flatten layer*. Lalu ada bagian kedua yang merupakan layer-layer seperti *Dense layer*, *Dropout layer*, dan lainnya. Terakhir ada output layer yang merupakan layer untuk menentukan sebuah kelas.

2.7 Arsitektur Convolutional Neural Network Transfer Learning

Arsitektur CNN merupakan gabungan dari beberapa layer yang secara umum terdiri dari *Convolutional Layer*, *Subsampling Layer (Pooling Layer)*, dan *Fully Connected Layer* (O'Shea dan Nash, 2015). *Layer* ini tersusun tanpa adanya aturan yang universal dan berbeda-beda tergantung dari dataset yang digunakan. Ada banyak arsitektur CNN yang telah didesain para ahli, yang pertama adalah *LeNet* (LeCun dkk., 1998) yang digunakan untuk membaca kode pos dan digit (Suyanto, 2018), namun karena keterbatasan perangkat dan waktu komputasi yang tinggi maka arsitektur ini sempat dilupakan karena dianggap tidak efektif saat itu.

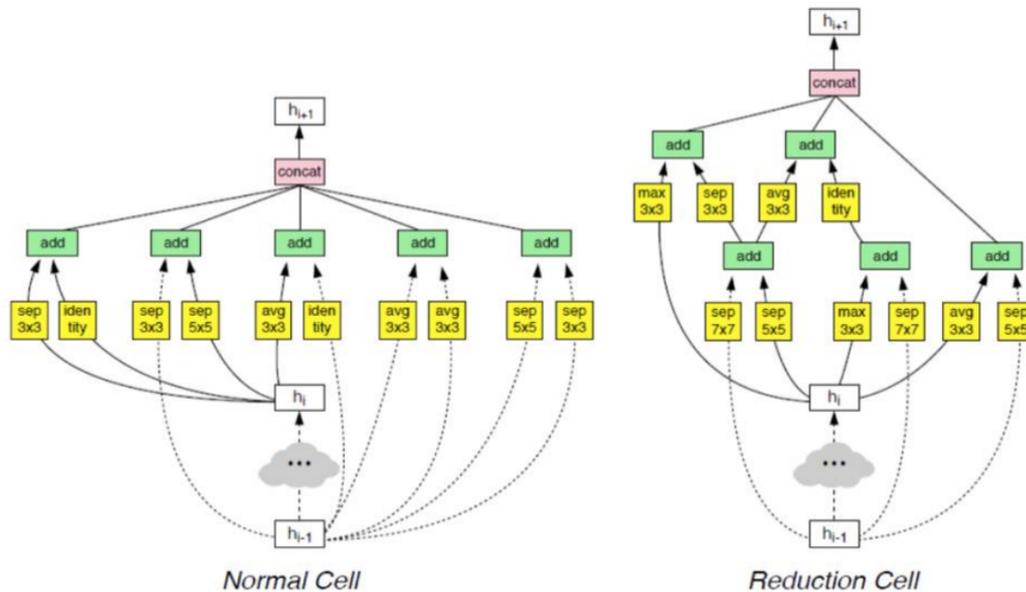
ImageNet setiap tahunnya mengadakan kompetisi untuk para peneliti di bidang *image processing*. Kompetisi tersebut yaitu *ImageNet Large Scale Visual Recognition Competition (ILSVRC)*. ILSVRC merupakan kompetisi *image processing* untuk menganalisis algoritma terhadap klasifikasi dan deteksi gambar dalam jumlah yang besar. Pada kompetisi tersebut para peneliti menguji arsitektur yang telah dirancang dengan dataset yang telah disediakan oleh *ImageNet*, sehingga arsitektur yang mencapai akurasi tertinggi akan dijadikan sebagai pemenang.

Transfer learning adalah metode menggunakan jaringan saraf yang sudah dilatih sebelumnya lalu mengurangi jumlah parameter dengan cara mengambil beberapa bagian dari model yang sudah dilatih untuk digunakan dalam mengenali model baru (Abas dkk., 2018). *Transfer learning* melatih model dengan memanfaatkan *ImageNet* sebagai pengetahuan umum untuk model. *ImageNet* merupakan sebuah dataset umum berjumlah besar dari Google. Dalam *transfer learning* terdapat beberapa istilah seperti *pre-trained* dan *fine tuning*. *Transfer learning* nantinya akan melatih model dengan menggunakan data besar, inilah yang disebut *pre-trained*. Pada *tensorflow*, *pre-trained* model dilakukan dengan menggunakan dataset *ImageNet*. Selain *pre-trained*, *fine-tuning* juga merupakan sebuah cara yang biasanya dipakai dalam melatih model. Model yang sudah dilakukan *pre-trained* akan dilatih lagi menggunakan data baru untuk kebutuhan lain. Dalam penelitian ini arsitektur yang digunakan adalah *NASNetLarge*, *DenseNet201*, dan *MobileNet*.

2.7.1 NASNetLarge

Arsitektur *NASNetLarge* yang ada di *Library Keras.io* adalah *NASNet-A (6 @ 4032)* atau *NASNetLarge*. Arsitektur *NASNetLarge* menerima input dengan ukuran 224×224 . *NASNet* merupakan model berdasarkan cara mencari blok arsitektur terbaik pada dataset yang kecil, setelah itu melakukan penyalinan arsitektur terbaik yang ditemukan. Kemudian tahap berikutnya digunakan pada dataset yang besar yakni *ImageNet*. Blok-blok tersebut disusun sedemikian rupa membentuk variasi arsitektur *NASNet*, variasi yang kecil adalah *NASNetMobile* atau *NASNet-A (4 @ 1056)*. Arsitektur *NASNet* berisikan dua blok utama yaitu

normal cell dan *reduction cell*. Layer dari kedua cell tersebut menggunakan *Recurrent Neural Network* (RNN).



Gambar 2.12 *Normal Cell* dan *Reduction Cell* pada Arsitektur *NASNetLarge* (Sumber gambar : Sik-Ho Tsang)

Pada gambar 2.12, *NASNetLarge* terdiri dari sekumpulan *normal cell* dan *reduction cell*, salah satu perbedaannya adalah dalam penggunaan *normal cell*, pada *NASNetLarge* terdapat 6 *normal cell* yang disusun secara *sequensial*. *NASNetLarge* berhasil mencapai performa *state-of-the-art* untuk klasifikasi gambar *ImageNet* dengan akurasi top-1 82.7% (Zoph B., dkk). Berdasarkan pustaka keras, model ini memiliki jumlah *layer* sebanyak 1039 yang terbagi ke dalam 18 *normal cell* dan 3 *reduction cell*.

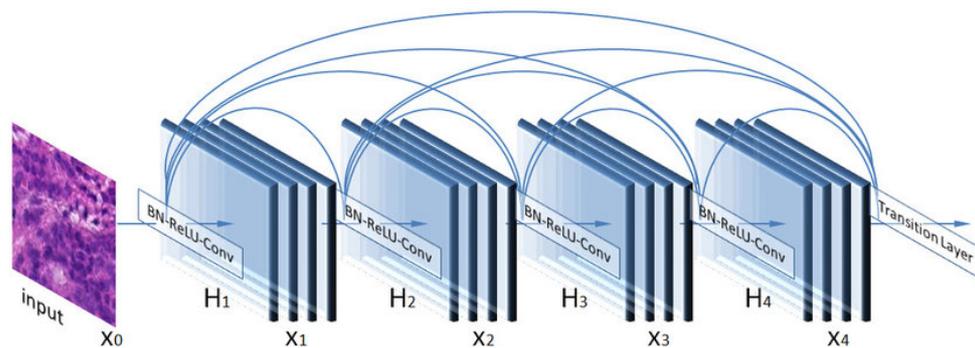
2.7.2 DenseNet201

DenseNet201 adalah jaringan saraf convolutional yang memiliki kedalaman 201 lapisan. Jaringan yang telah dilatih dapat mengklasifikasikan gambar ke dalam 1000 kategori objek, seperti keyboard, mouse, pensil, dan banyak hewan. Akibatnya, jaringan telah mempelajari representasi fitur yang kaya untuk berbagai gambar.

Dense Convolutional Network (DenseNet) menghubungkan setiap lapisan ke setiap lapisan lainnya dengan cara *feed-forward*. Mereka meringankan masalah gradien menghilang, memperkuat propagasi fitur, mendorong penggunaan kembali

fitur, dan secara substansial mengurangi jumlah parameter. Arsitektur *DenseNet201* menerima input dengan ukuran 224×224 .

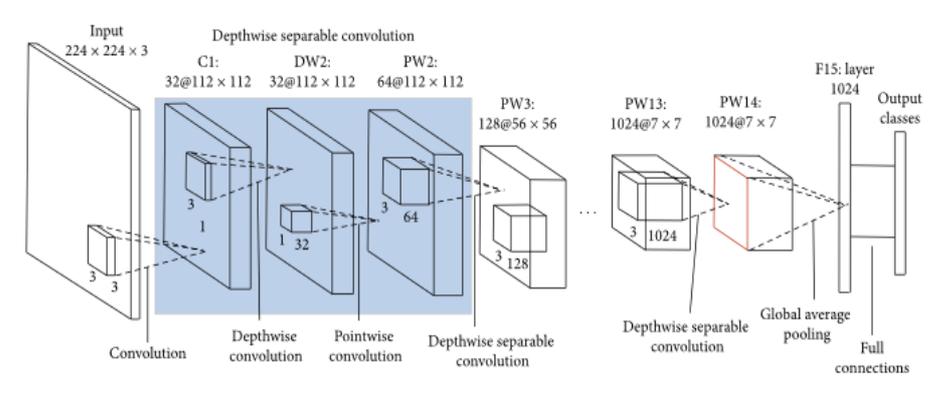
DenseNet bekerja pada gagasan bahwa jaringan konvolusi dapat jauh lebih dalam, lebih akurat, dan efisien untuk dilatih jika mereka memiliki koneksi yang lebih pendek antara lapisan yang dekat dengan input dan yang dekat dengan output. Alur kerja arsitektur model *DenseNet201* ditunjukkan pada gambar 2.13.



Gambar 2.13 Arsitektur Model *DenseNet201*
(Sumber gambar : Amit Kumar Jaswal)

2.7.3 MobileNet

MobileNet merupakan model yang memiliki ukuran kecil baik dari jumlah parameter maupun ukuran model yang dihasilkan. Seperti namanya, *Mobile*, para peneliti dari *Google* membuat arsitektur CNN yang dapat digunakan untuk kebutuhan *mobile*. Perbedaan mendasar antara arsitektur *MobileNet* dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau *layer* konvolusi dengan ketebalan filter yang sesuai dengan ketebalan *input image* (Putri., dkk). Arsitektur *MobileNet* menerima input dengan ukuran 224×224 . Perbedaan mendasar antara arsitektur *MobileNet* dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau *layer* konvolusi dengan ketebalan filter yang sesuai dengan ketebalan *input image*. Alur kerja arsitektur model *MobileNet* ditunjukkan pada gambar 2.14.



Gambar 2.14 Arsitektur Model *MobileNet*
(Sumber gambar : Abhijeet Pujara)

Gambar 2.14 menunjukkan gambar *depthwise separable convolutions*, yakni blok *layer* yang tersusun dari *depthwise convolution* dan *pointwise convolution*. masing-masing *layer* tersebut diikuti oleh *batch normalization* dan *ReLU nonlinearity*. Blok *layer* tersebut kemudian disusun secara berulang membentuk arsitektur *MobileNet*. Berdasarkan pustaka keras, *MobileNet* memiliki jumlah *layer* sebanyak 28 *convolution layer* dan 1 *fully connected layer* yang diikuti oleh lapisan *softmax*.

2.8 Evaluasi Kinerja Model

Evaluasi kinerja model merupakan yang terpenting dalam menentukan suatu model bagus atau tidak. Pada kasus klasifikasi, evaluasi kinerja yang digunakan berupa *Confusion matrix*, *precision*, *recall*, *accuracy* dan *F1-score*. Terdapat beberapa pengukuran kinerja model yang digunakan dalam penelitian ini.

1. Confusion Matrix

Confusion Matrix adalah pengukuran performa untuk masalah klasifikasi *machine learning* dimana keluaran dapat berupa dua kelas atau lebih. *Confusion Matrix* adalah tabel dengan 4 kombinasi berbeda dari nilai prediksi dan nilai aktual. Ada empat istilah yang merupakan representasi hasil proses klasifikasi pada *confusion matrix* yaitu *True Positive*, *True Negative*, *False Positive*, dan *False Negative*

- a. *True Negative* (TN) merupakan jumlah data negatif yang terdeteksi dengan benar.

- b. *False Positive* (FP) merupakan data negatif namun terdeteksi sebagai data positif.
- c. *True Positive* (TP) merupakan data positif yang terdeteksi benar.
- d. *False Negative* (FN) merupakan kebalikan dari *True Positive*, data positif namun terdeteksi sebagai data negatif, berikut rumus dari *Confusion Matrix* di Tabel 2.1.

Tabel 2.1 *Confusion Matrix*

DATA ACTUAL	PREDICTION			
	NO TUMOR	PITUITARY TUMOR	MENINGIOMA TUMOR	GLIOMA TUMOR
NO TUMOR	TN	FP	FP	FP
PITUITARY TUMOR	FN	TP	FP	FP
MENINGIOMA TUMOR	FN	FP	TP	FP
GLIOMA TUMOR	FN	FP	FP	TP

2. Presisi

Presisi merupakan rasio prediksi benar positif (*True Positive*) dibandingkan dengan keseluruhan hasil yang diprediksi positif. Rumus dari presisi dinyatakan pada persamaan (2.2)

$$\text{Precision} = (TP) / (TP+FP) \quad (2.2)$$

3. Recall

Recall atau rasio *true positive* adalah rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Kadang juga disebut kepekaan (*sensitivity*). Rumus *recall* dapat dituliskan seperti pada persamaan (2.3).

$$\text{Recall} = (TP) / (TP + FN) \quad (2.3)$$

4. Akurasi dan Validasi Akurasi

Akurasi digunakan untuk mengukur kinerja algoritma dengan cara yang dapat ditafsirkan. Akurasi suatu model biasanya ditentukan dalam bentuk persentase. Akurasi adalah ukuran seberapa akurat prediksi model dibandingkan dengan data sebenarnya dan Akurasi dihitung berdasarkan *data train*. Rumus untuk akurasi ditunjukkan pada persamaan (2.4).

$$akurasi = \frac{(TP + TN)}{(TP + TN + FP + FN)} * 100\% \quad (2.4)$$

Sedangkan validasi akurasi dihitung berdasarkan data validasi. Yang terbaik adalah mengandalkan validasi akurasi dari kinerja model, karena *neural network* yang baik pada akhirnya akan menyesuaikan data train pada 100%, tetapi akan berkinerja buruk pada data yang baru ditemuinya.

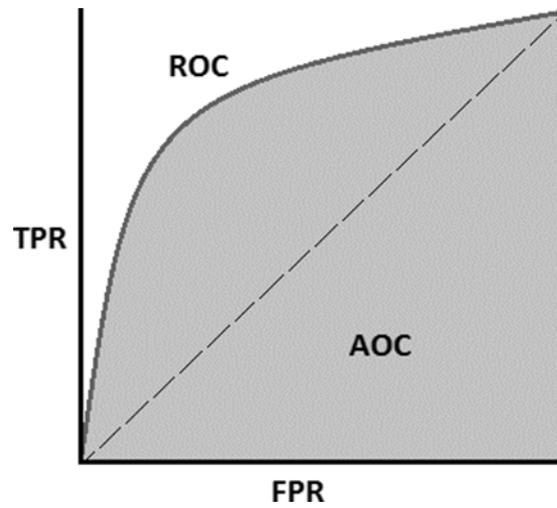
5. F1-Score

F1-Score atau Skor F1 adalah skor *F* yang paling umum digunakan. Ini adalah kombinasi presisi dan *recall*, yaitu rata-rata harmoniknya. *F1-Score* dapat dihitung melalui persamaan (2.5).

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (2.5)$$

6. Kurva ROC-AUC

Kurva AUC-ROC adalah pengukuran kinerja untuk masalah klasifikasi pada berbagai pengaturan ambang batas. *Receiver Operator Characteristic* (ROC) adalah kurva probabilitas dan *Area Under the Curve* (AUC) adalah ukuran yang digunakan sebagai ringkasan dari kurva ROC. Ini memperlihatkan seberapa besar model mampu membedakan antar kelas. Semakin tinggi AUC, semakin baik model dalam memprediksi 0 sebagai 0 dan 1 sebagai 1. Dengan analogi, semakin tinggi AUC, semakin baik model dalam membedakan antara pasien dengan penyakit dan tidak ada penyakit.



Gambar 2.15 Kurva AUC – ROC
(Sumber gambar : Tina Gongting)

Kurva ROC diplotkan dengan *True Positive Rate*(TPR) terhadap *False Positive Rate*(FPR) dimana TPR berada pada sumbu *y* dan FPR pada sumbu *x* seperti yang terlihat pada Gambar 2.15.