

Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN Dengan Arsitektur Alexnet

1st Kristina Amalia
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
kristinaamalia@telkomuniversity.
ac.id

2nd Rita Magdalena
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ritamagdalenat@telkomuniversity.
ac.id

3rd Sofia Saidah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
sofiasaidahsfi@telkomuniversity.a
c.id

Abstrak

Tumor otak merupakan salah satu penyakit

berbahaya yang dapat mengganggu kerja otak. Penyakit ini dapat dideteksi dengan melakukan *Magnetic Resonance Imaging (MRI) Scan*. Saat ini para radiolog mendiagnosis penyakit tumor otak secara manual dengan membaca hasil citra MRI otak pasien. Namun, cara tersebut dapat mengurangi akurasi diagnosis karena keterbatasan mata manusia yang rentan terhadap kesalahan. Pada Tugas Akhir ini, dirancang suatu sistem berbasis *deep learning*, yaitu *Convolutional Neural Network (CNN)* dengan arsitektur AlexNet. Jumlah *dataset* yang digunakan dalam penelitian ini sebanyak 6484 citra MRI dengan empat kelas yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor* yang bersumber dari Kaggle.com. Pada sistem ini dilakukan pengujian terhadap beberapa parameter untuk mendapatkan hasil yang optimal. Parameter yang diuji yaitu ukuran citra, rasio data, *optimizer*, *learning rate*, ukuran *batch* dan jumlah *epoch*. Parameter tersebut selanjutnya dianalisis berdasarkan akurasi, *loss*, *recall*, presisi, dan *F1 Score*. Berdasarkan hasil pengujian, diperoleh parameter terbaik yang mempengaruhi kinerja sistem, yaitu menggunakan ukuran citra 224x224 piksel, rasio data latih 80%, data validasi 10%, serta data uji 10%, menggunakan *Adam optimizer*, *learning rate* 0.0001, menggunakan *batch size* 8 dan nilai *epoch* 50. Hasil terbaik yang didapatkan yaitu akurasi sebesar 98,84%, *loss* sebesar 0,1616, dengan nilai presisi 97,65%, *recall* 97,65%, dan *F1 Score* 97,65%.

Kata Kunci : Tumor otak, Klasifikasi, *Convolutional Neural Network*, AlexNet

Abstract

Brain tumors are one of the dangerous diseases that can affect brain performance. This disease can be detected by performing a Magnetic Resonance Imaging (MRI) Scan. Currently, radiologists diagnose brain tumors manually by reading the MRI image of patient's brain. However, this method can reduce the

accuracy due to the limitations of the human eye which is prone to errors. In this final project, a deep learning-

based system was designed, using Convolutional Neural Network (CNN) with AlexNet architecture. This study used 6484 MRI images with four classes, namely glioma, meningioma, pituitary, and no tumor sourced from Kaggle.com. In this final project, several parameters were tested to reach optimal results, which are image size, data ratio, types of optimizers, learning rate, batch size and number of epochs. These parameters are then analyzed based on accuracy, loss, recall, precision, dan F1 Score. Based on results, system can work optimally using 224x224 pixels of image size, 80% ratio of training data, 10% of validation data, 10% of testing data, using Adam optimizer, learning rate 0.0001, batch size 8 and number of epochs are 50. The best results obtained 98,84% of accuracy, 0,1616 of loss, 97,65% of precision, 97,65% of recall, and 97,65% of F1 Score.

Keywords: Brain tumor, Classification, *Convolutional Neural Network*, Alexnet

I. PENDAHULUAN

Otak merupakan bagian dari sistem saraf pusat dan terletak pada bagian kepala manusia. Sebagai sistem saraf pusat, otak berperan untuk mengatur semua fungsi dan organ tubuh lainnya. Tumor otak merupakan pertumbuhan sel-sel yang tidak seharusnya berada pada daerah otak [1]. Tumor otak dibedakan menjadi dua yaitu tumor otak primer dan tumor otak *metastatic*. Tumor otak primer berasal dari sel yang berada di dalam otak, Tumor otak *metastatic* adalah sel kanker yang berasal dari anggota tubuh lain yang menyebar ke otak. Tumor otak terbagi kedalam beberapa tipe, diantaranya Gliomas, Meningiomas, dan Pituitary [2]. Berdasarkan *Global Cancer Observatory* tahun 2020, kasus tumor otak di Indonesia menempati urutan ke-15 sebagai penyakit dengan jumlah kasus terbanyak dan jumlah rata-rata kematian 15.310 kasus dalam

lima tahun terakhir [3]. Proses klasifikasi pada tahap awal penyakit ini perlu dilakukan, mengingat para tenaga medis mendeteksi tumor otak berdasarkan citra MRI dengan mata telanjang dapat menyebabkan rendahnya akurasi. Perkembangan metode *deep learning* dapat membantu radiolog dalam mendiagnosis tumor otak dalam menghasilkan akurasi yang lebih baik.

CNN merupakan salah satu model pembelajaran *deep learning* yang mampu melatih sistem dengan data yang cukup banyak serta menggabungkan proses ekstraksi ciri dan klasifikasi. CNN memiliki beberapa arsitektur, salah satu arsitekturnya adalah AlexNet [4]. Arsitektur Alexnet [5] merupakan model pertama yang diuji pada *dataset* berskala besar seperti ImageNet, sehingga Alexnet sebagai salah satu pelopor *deep neural networks* pada *computer vision*. Pada Tugas Akhir ini, sistem mengklasifikasikan citra tumor otak ke dalam 4 kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Penelitian Tugas Akhir ini bertujuan untuk menentukan parameter terbaik yang mempengaruhi sistem dalam mendeteksi tumor otak sehingga hasilnya dapat membantu para tenaga medis dalam mendiagnosis pasien penderita tumor otak.

II. KAJIAN TEORI

Penelitian dengan menggunakan metode *Support Vector Machine* (SVM) untuk mengklasifikasikan citra otak normal dan tumor telah dilakukan oleh para peneliti sebelumnya. Penelitian tersebut menggunakan 36 citra yang bersumber dari Kaggle.com dan www.figshare.com. Ekstraksi ciri yang digunakan dalam penelitian tersebut adalah *Gray Level Co-occurrence Matrix* (GLCM) dan mendapatkan akurasi rata-rata sebesar 93.05% [6]. Pada penelitian selanjutnya membandingkan dua metode klasifikasi, yaitu *Decision Tree* dan *Naïve*

Bayes, sistem menggunakan metode segmentasi *K-means clustering* dan ekstraksi fitur GLCM untuk mengklasifikasikan citra dengan tumor otak dan citra otak normal. *Dataset* yang digunakan dalam penelitian ini bersumber dari Kaggle dengan jumlah 30 citra tumor dan 30 citra tidak tumor. Hasil dari penelitian ini menunjukkan bahwa akurasi metode *Decision Tree* lebih tinggi sebesar 96% sedangkan *Naïve Bayes* mendapatkan akurasi sebesar 91%. Penelitian dengan mengklasifikasikan citra MRI tumor otak ke dalam 3 kelas, yaitu *astrocytoma*, *glioblastoma*, dan *oligodendroglioma* yang diperoleh dari *The Cancer Imaging Archive*. Metode pada penelitian tersebut menggunakan *K-Nearest Neighbour* dan teknik segmentasi berupa *Morphological Gradient* dan *Watershed*. Hasil yang didapatkan dengan menggunakan metode ini sebesar 89.5% [7]. Pada penelitian dengan membandingkan dua metode

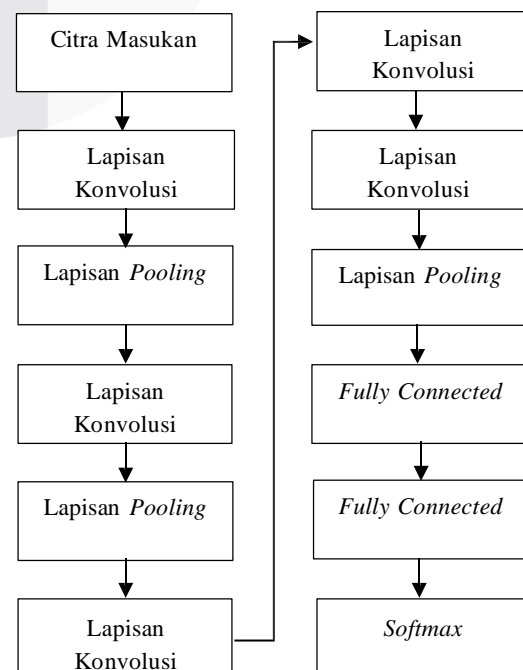
klasifikasi yaitu *Convolutional Neural Network* (CNN) dan SVM yang terdiri dari 2 jenis yaitu Linear SVM dan Polynomial SVM. Citra yang digunakan dalam penelitian ini berjumlah 3064 citra MRI yang diambil dari 233 pasien Rumah Sakit Nanfang dan Tianjing Medical University. Pengklasifikasian citra tumor otak ke dalam 3 kelas, yaitu *meningioma*, *glioma* dan *pituitary* ini mendapatkan tingkat akurasi sebesar 98.85%, 95.27%, dan 95.43% untuk CNN, Linear SVM dan Polynomial SVM [8]. Penelitian klasifikasi tumor otak menggunakan metode CNN ke dalam 2 kelas yaitu tumor dan *non-tumor* mendapatkan akurasi 97.5%. Peneliti mengumpulkan citra yang bersumber dari repositori publik yang berbeda, yaitu Radiopaedia dan Brain Tumor Image Segmentation Benchmark (BRATS) 2015. Penelitian tersebut menggunakan fitur ekstraksi yang terdapat pada CNN, sehingga mendapatkan hasil akurasi yang tinggi dan kompleksitas yang rendah [9].

III. METODE

Sistem yang dirancang pada Tugas Akhir ini merupakan pengklasifikasian penyakit tumor otak yang terdiri dari empat kelas, yaitu *meningioma*, *glioma*, *pituitary*, dan *no tumor*. Metode yang digunakan dalam merancang sistem ini berupa *Convolutional Neural Network* dengan arsitektur AlexNet. Model sistem yang dirancang pada penelitian ini adalah sebagai berikut.

A. Model Sistem

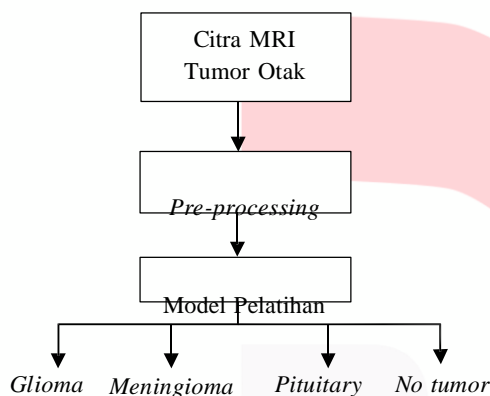
Sistem yang dirancang pada penelitian ini merupakan pengklasifikasian penyakit tumor otak yang terdiri dari empat kelas, yaitu *meningioma*, *glioma*, *pituitary*, dan *no tumor*. Metode yang digunakan dalam merancang sistem ini berupa *Convolutional Neural Network* dengan arsitektur AlexNet.



GAMBAR 1 Arsitektur AlexNet

Alexnet merupakan model pertama yang diuji pada *dataset* berskala besar seperti ImageNet, sehingga Alexnet sebagai salah satu pelopor *deep neural networks* pada *computer vision*. AlexNet mempunyai jumlah layer yang lebih sedikit dibandingkan dengan arsitektur yang ada saat ini. AlexNet terdiri dari 8 lapisan parameter, 5 lapisan pertama adalah lapisan konvolusi, dan 3 lainnya adalah lapisan *fully connected*. AlexNet menerapkan *dropout* pada 2 lapisan pertama *fully connected layer* untuk mengurangi *overfitting* [4].

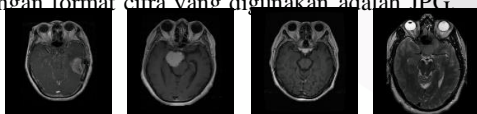
Pada bagian ini, penulis menjelaskan desain sistem yang dirancang.



GAMBAR 2 Model perancangan sistem

1. Citra MRI Tumor Otak

Citra MRI tumor otak yang digunakan sebagai *dataset* pada sistem ini merupakan data sekunder yang diperoleh dari web www.kaggle.com [10]. Jumlah *dataset* yang digunakan berupa 6484 citra MRI tumor otak yang mencakup 4 kelas yaitu *meningioma*, *glioma*, *pituitary* dan *no tumor* dengan format citra yang digunakan adalah *IPG*.



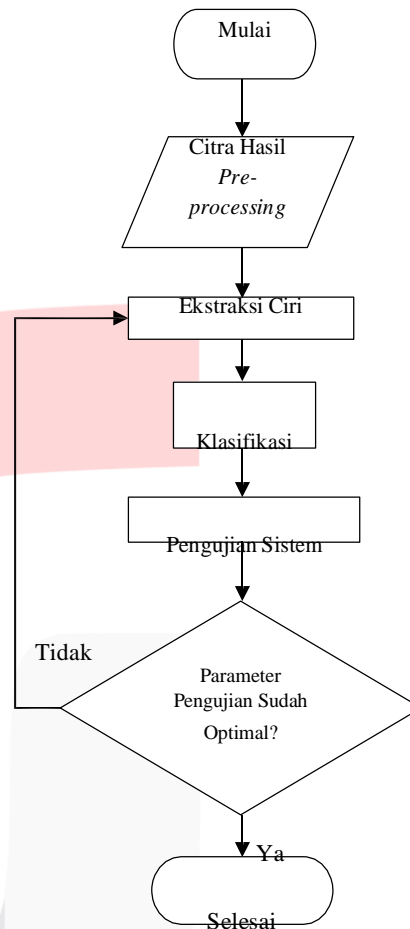
GAMBAR 3 (a) Glioma (b) Meningioma (c) Pituitary (d) No Tumor

2. Pre-processing

Pada penelitian ini tahap *pre-processing* terdiri dari proses konversi citra RGB ke *grayscale* dan *resizing* citra. *Dataset* yang diperoleh memiliki jenis citra RGB yang mempunyai 3 kanal sehingga mempunyai kompleksitas citra yang tinggi, maka pada sistem ini dikonversi menjadi citra *grayscale* untuk menyederhanakan model citra. Selain itu, citra yang didapatkan mempunyai ukuran yang berbeda-beda, maka dilakukan proses

resizing agar mendapatkan ukuran citra yang sama. Tujuan tahap *pre-processing* adalah memudahkan sistem pada proses selanjutnya karena citra mempunyai ukuran yang seragam.

3. Pelatihan Model



GAMBAR 4 Diagram Alir Model Pelatihan Sistem

Masukan terdiri dari 4 kelas citra, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Pada tahap *pre-processing* dilakukan proses konversi citra ke *grayscale* dan *resizing*. Citra hasil *pre-processing* tersebut selanjutnya digunakan oleh sistem sebagai masukan selama proses pelatihan.

Proses pelatihan ini menggunakan metode *Convolutional Neural Network* dengan arsitektur Alexnet. Pertama, citra akan melalui proses ekstraksi ciri yang terdapat pada lapisan konvolusi, dan *pooling*. Pada proses ini, sistem melakukan pengambilan informasi penting pada citra.

Tahap klasifikasi terdapat pada *fully connected layer* dan aktivasi *softmax* yang berfungsi untuk menghasilkan keluaran sesuai dengan kelas tumor otak. Pada lapisan *fully connected*, terdapat fungsi *dropout* yang berguna

untuk menghindari *overfitting*. Tahap terakhir yaitu pengujian sistem yang terdiri dari beberapa skenario pengujian untuk menentukan kinerja sistem yang terbaik.

Setelah dilakukan pelatihan, maka sistem diuji untuk menentukan kinerjanya dalam mengklasifikasi citra ke dalam kelas yang sesuai. Pengujian terdiri dari beberapa skenario parameter yang mempengaruhi kinerja sistem. Pengujian terus dilakukan hingga mendapatkan skenario parameter terbaik dalam mengklasifikasi citra tumor otak ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary* dan *no tumor*.

B. Skenario Pengujian

Pengujian terdiri dari enam skenario untuk mencari parameter yang optimal pada sistem klasifikasi penyakit tumor otak. Skenario tersebut yaitu pengujian ukuran citra untuk mendapatkan ukuran citra yang optimal, skenario pengujian

rasio data latih, data validasi, dan data uji untuk mendapatkan rasio terbaik, skenario pengujian *optimizer* untuk menentukan *optimizer* yang dapat menghasilkan kinerja sistem yang optimal,

skenario pengujian *learning rate*, skenario pengujian *batch size*, dan skenario pengujian *epoch* untuk mendapatkan performansi terbaik sistem.

C. Pengukuran Kinerja

Tahapan ini menguji kinerja sistem yang telah dirancang, agar diketahui seberapa efektif sistem dalam mengklasifikasikan citra sesuai dengan kelas yang diinginkan, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Kinerja sistem dapat terlihat dengan menganalisis nilai akurasi, *loss*, presisi, *recall*, dan *F1 Score*. Selain itu, terdapat juga *confusion matrix* yang terdiri dari nilai aktual dan nilai prediksi, di mana nilai tersebut dapat membantu menunjukkan kemampuan klasifikasi sistem ke dalam kelas yang sesuai.

Pada tabel *confusion matrix* terdapat nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) yang dipakai untuk mencari nilai parameter pengujian.

Aktual \ Prediksi	Kelas				
	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>	<i>No tumor</i>	
<i>Glioma</i>	C_1	C_2	C_3	C_4	
<i>Meningioma</i>	C_5	C_6	C_7	C_8	
<i>Pituitary</i>	C_9	C_{10}	C_{11}	C_{12}	
<i>No tumor</i>	C_{13}	C_{14}	C_{15}	C_{16}	

GAMBAR 5 *Confusion matrix*

TP merupakan data aktual yang dapat diprediksi dengan benar. Contohnya pada kelas *glioma*, nilai C_1 merupakan nilai TP. TN merupakan penjumlahan semua nilai pada matriks tanpa melibatkan nilai kolom dan baris kelas yang

dihitung. Contohnya nilai penjumlahan $C_2 + C_3 + C_4 + C_5 + C_6 + C_7 + C_8$ merupakan nilai TN untuk kelas *glioma*. FP merupakan penjumlahan nilai kolom pada kelas yang dihitung, tanpa melibatkan nilai TP. Contohnya nilai $C_1 + C_2 + C_3$ merupakan nilai FP untuk kelas *glioma*. FN merupakan penjumlahan nilai baris pada kelas yang dihitung, tanpa melibatkan nilai TP. Contohnya $C_1 + C_2 + C_3$ merupakan nilai FN untuk kelas *glioma*.

Setelah mencari nilai tersebut, maka hasil tersebut dapat digunakan untuk menghitung nilai akurasi, presisi, *recall*, *F1 Score* dan *loss*.

1. Akurasi

Akurasi merupakan rasio pengukuran nilai prediksi dengan nilai sebenarnya. Rumusan akurasi dapat dituliskan ke dalam persamaan berikut [8]:

$$\text{Akurasi} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \quad (1)$$

2. Presisi

Presisi merupakan perbandingan antara nilai yang berhasil diprediksi dengan benar terhadap seluruh nilai yang diprediksi oleh sistem. Secara sistematis dituliskan kedalam persamaan berikut [8]:

$$\text{Presisi} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

Di mana k merupakan kelas citra

3. Recall

Recall merupakan perbandingan antara nilai yang berhasil diprediksi benar oleh sistem terhadap seluruh nilai aktualnya. Secara sistematis dapat dituliskan ke dalam persamaan sebagai berikut :

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

Di mana k merupakan kelas citra

4. F1 Score

F1 Score merupakan perbandingan rata-rata hasil presisi dan *recall* yang telah didapatkan. Secara sistematis dapat dituliskan ke dalam persamaan berikut [8]:

$$F1 = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

5. Loss

Loss function digunakan untuk menghitung *error* antara nilai yang diprediksi dengan nilai aktualnya. Penelitian ini menggunakan *cross*

entropy loss function yang umumnya digunakan untuk *multiclass*. Secara sistematis disajikan ke dalam persamaan berikut [4] :

$$(-\sum_{i=1}^n p_i \log p_i) \quad (5)$$

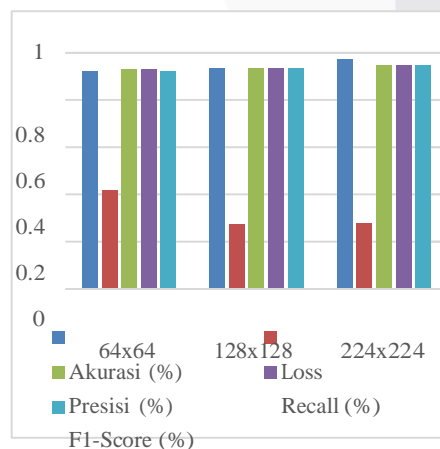
Di mana n merupakan kelas citra, y merupakan keluaran yang diinginkan, sedangkan p adalah probabilitas untuk setiap keluaran kelas.

IV. HASIL DAN PEMBAHASAN

Pada bagian ini, berisi hasil skenario pengujian kinerja sistem klasifikasi tumor otak menggunakan metode CNN. Pengujian terdiri dari enam skenario yang mempengaruhi performansi sistem. Kinerja sistem dilihat berdasarkan nilai akurasi, *loss*, *recall*, presisi, dan *F1 Score*. Berdasarkan hasil skenario pengujian yang terbaik, penulis menganalisis parameter yang optimal dalam sistem klasifikasi tumor otak ini.

A. Skenario Pengujian Ukuran Citra

Skenario pertama yaitu pengujian ukuran citra. Skenario ini bertujuan untuk mendapatkan ukuran citra terbaik. Ukuran yang dibandingkan adalah 64x64 piksel, 128x128 piksel, dan 224x224 piksel. Parameter lain yang membantu skenario ini, yaitu menggunakan rasio 80% data latih, 10% data validasi dan 10% data uji, menggunakan *Adam optimizer*, nilai *learning rate* 0.0001, *batch size* 32 dan *epoch* 50.



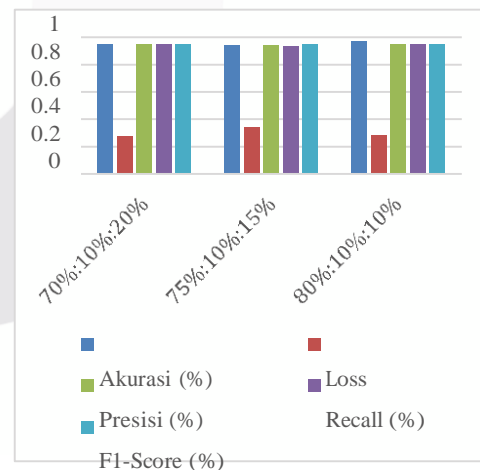
GAMBAR 6 Hasil pengujian skenario ukuran citra

Berdasarkan hasil pengujian dapat disimpulkan bahwa kinerja sistem pada ukuran citra 224x224

piksel adalah yang paling optimal dengan nilai akurasi 97,30%, *loss* sebesar 0,2788, *recall* sebesar 94,62%, presisi sebesar 94,61%, dan *F1 Score* sebesar 94,58%. Hal ini menandakan bahwa dengan ukuran citra yang lebih besar, sistem dapat lebih teliti dalam mengenali informasi dari citra. Pada citra 128x128 piksel menghasilkan *loss* yang lebih rendah dibandingkan 224x224 piksel. Namun, penulis tetap mengambil ukuran citra 224x224 piksel sebagai parameter yang terbaik karena melihat nilai pengujian lainnya, seperti akurasi, presisi, *recall*, dan *F1 Score* yang masih lebih baik dari ukuran 128x128 piksel. Ukuran 224x224 piksel menjadi parameter terbaik dan dipakai untuk skenario selanjutnya.

B. Skenario Pengujian Rasio Data

Skenario kedua yaitu pengujian rasio data latih, data uji, dan data validasi yang digunakan untuk model pelatihan sistem. Skenario ini bertujuan untuk mengetahui rasio terbaik untuk sistem klasifikasi tumor otak. Rasio yang dibandingkan adalah 70% : 10% : 20%, 75% : 10% : 15%, dan 80% : 10% : 10% untuk data latih, data validasi, dan data uji. Pada skenario ini menggunakan ukuran citra terbaik pada skenario sebelumnya, yaitu 224x224 piksel, dan parameter lainnya, yaitu menggunakan *Adam optimizer*, nilai *learning rate* 0.0001, *batch size* 32, dan *epoch* 50.



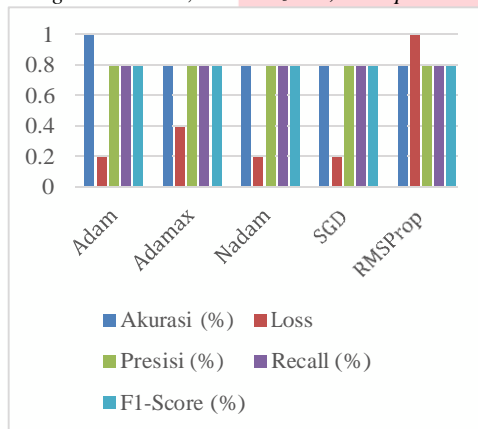
GAMBAR 7 Hasil pengujian skenario rasio data

Hasil pada pengujian ini menunjukkan bahwa rasio 80% data latih, 10% data validasi, dan 10% data uji mendapatkan hasil yang terbaik berdasarkan nilai akurasi sebesar 97,30%, *loss* sebesar 0,2788, presisi sebesar 94,61%, *recall* sebesar 94,62% dan *F1 Score* sebesar 94,58%

dibandingkan dengan rasio pengujian lainnya. Hal ini menandakan bahwa semakin banyak rasio pada data latih, maka sistem lebih banyak belajar mengenali informasi pada citra. Hasil tersebut merupakan parameter yang optimal untuk sistem dan digunakan pada skenario selanjutnya

C. Skenario Pengujian *Optimizer*

Skenario ketiga dilakukan untuk mencari *optimizer* terbaik yang mampu meningkatkan nilai akurasi secara optimal dan meminimalisir *loss*. *Optimizer* yang dibandingkan adalah Adam, Adamax, Nadam, RMSprop, dan SGD. Ukuran citra serta rasio data latih, data validasi dan data uji menggunakan hasil terbaik dari skenario pengujian sebelumnya. Parameter lainnya yang mendukung pengujian ini yaitu menggunakan *learning rate* 0.0001, *batch size* 32, dan *epoch* 50.



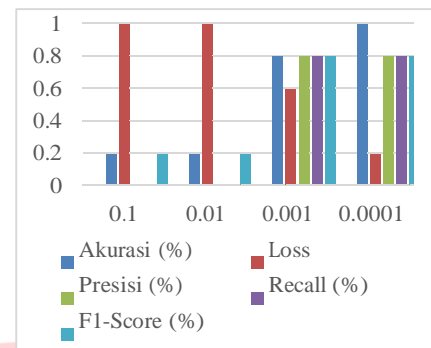
GAMBAR 8 Hasil pengujian skenario *optimizer*

Pada Gambar 8 terlihat bahwa *adam optimizer* mendapatkan hasil yang terbaik dengan akurasi 97,30%, *loss* sebesar 0,2788, presisi sebesar 94,61%, *recall* sebesar 94,62%, dan *F1 Score* sebesar 94,58%. Berdasarkan nilai tersebut, dapat disimpulkan bahwa dengan menguji lima *optimizer* yang berbeda, *Adam optimizer* mendapatkan hasil yang optimal untuk digunakan pada sistem ini dibandingkan dengan *optimizer* lainnya.

D. Skenario Pengujian *Learning Rate*

Skenario keempat dilakukan untuk mengetahui *learning rate* yang optimal dalam sistem klasifikasi tumor otak. Nilai yang dibandingkan yaitu 0.1, 0.01, 0.001 dan 0.0001. Skenario ini memerlukan hasil terbaik dari skenario sebelumnya, yaitu ukuran citra 224x224 piksel, rasio 80% data latih, 10% data validasi dan 10%

data uji, serta menggunakan *Adam optimizer*. Parameter lain yang digunakan yaitu menggunakan *batch size* 32, serta jumlah *epoch* 50.

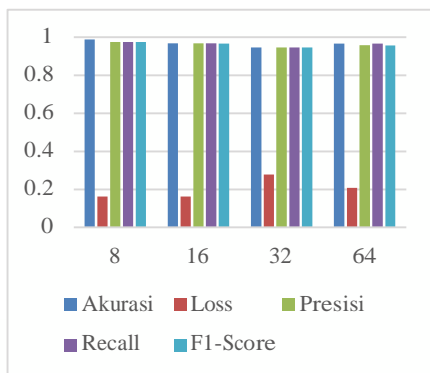


GAMBAR 9 Hasil pengujian skenario *learning rate*

Hasil pada pengujian parameter ini cukup signifikan perbedaannya, terlihat pada Gambar 9 yang menunjukkan bahwa nilai *learning rate* terbaik adalah 0.0001 dibandingkan dengan tiga nilai lainnya. Hasil akurasi yang dicapai sebesar 97,30%, *loss* sebesar 0,2788, presisi sebesar 94,61%, *recall* sebesar 94,62%, dan *F1 Score* sebesar 94,58%. Nilai *learning rate* yang semakin kecil dapat mempengaruhi kinerja sistem yang lebih detail dalam proses pelatihan. Nilai *learning rate* yang besar dapat menyebabkan terlewatnya titik optimal, sehingga pada pengujian ini menunjukkan bahwa sistem lebih optimal jika menggunakan nilai *learning rate* yang kecil. Oleh karena hasil tersebut, penulis menggunakan *learning rate* 0.0001 pada skenario selanjutnya sebagai nilai yang optimal.

E. Skenario Pengujian *Batch Size*

Skenario kelima yaitu pengujian *batch size* yang digunakan untuk model pelatihan sistem. Skenario ini bertujuan untuk mencari ukuran *batch* terbaik. Ukuran *batch* yang diuji yaitu 8, 16, 32, dan 64. Pada pengujian ini menggunakan hasil yang terbaik dari parameter sebelumnya, yaitu ukuran citra 224x224 piksel, dengan rasio 80% data latih, 10% data validasi dan 10% data uji, menggunakan *Adam optimizer*, dan *learning rate* 0.0001. Parameter lainnya yaitu menggunakan *epoch* 50.

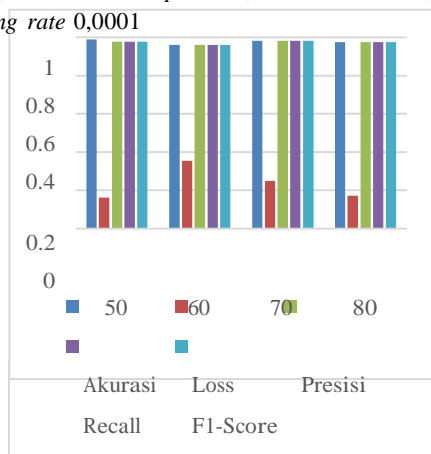


GAMBAR 10 Hasil pengujian skenario *batch size*

Pada Gambar 10 menunjukkan bahwa ukuran *batch* 8 merupakan ukuran *batch* yang stabil pada sistem ini dibandingkan *batch size* lainnya. Pengujian dengan ukuran *batch* 8, 16, 32, dan 64 menghasilkan perbedaan akurasi yang cukup signifikan. Akurasi yang didapatkan dengan menggunakan ukuran *batch* 8 adalah 98,84%, *loss* sebesar 0,1616, presisi sebesar 97,65%, *recall* sebesar 97,65%, dan *F1 Score* sebesar 97,65%. Hasil pada pengujian ini menunjukkan bahwa ukuran *batch* yang kecil menghasilkan akurasi yang lebih besar dan *loss* yang lebih kecil. Hasil pada pengujian ini digunakan pada skenario selanjutnya sebagai parameter yang terbaik.

F. Skenario Pengujian *Epoch*

Skenario keenam yaitu pengujian jumlah *epoch*. Skenario ini dilakukan untuk mendapatkan jumlah *epoch* terbaik yang dapat meningkatkan kinerja sistem. Jumlah *epoch* yang dibandingkan adalah 50, 60, 70 dan 80. Memanfaatkan seluruh hasil terbaik dari skenario-skenario sebelumnya, yaitu ukuran citra 224x224 piksel, rasio 80% data latih, 10% data validasi, 10% data uji, menggunakan *Adam optimizer*, *batch size* 8, dan *learning rate* 0,0001

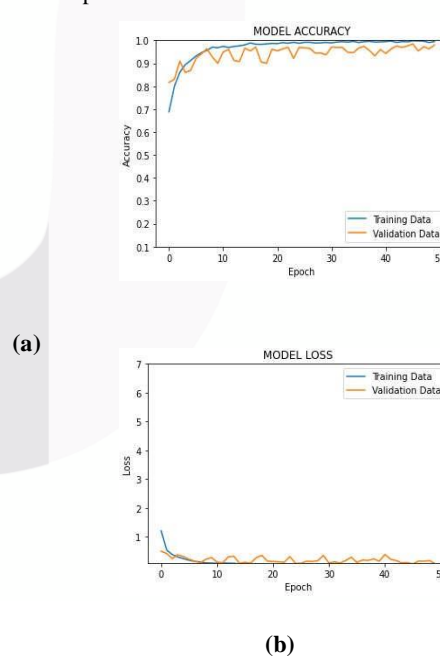


GAMBAR 11 Hasil pengujian skenario

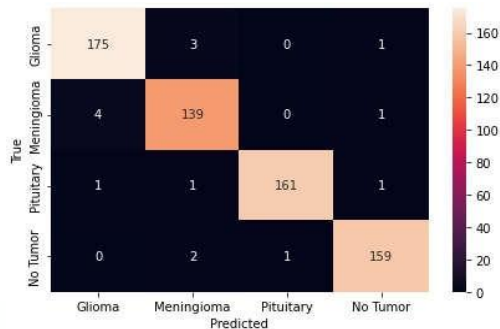
epoch

Pada Gambar 11 dapat dilihat bahwa kinerja sistem yang optimal terdapat pada *epoch* 50 dibandingkan dengan nilai *epoch* lainnya. Nilai akurasi yang didapatkan yaitu 98,84%, *loss* sebesar 0,1616, presisi sebesar 97,65%, *recall* 97,65%, dan *F1 Score* sebesar 97,65%. Pada skenario pengujian terhadap *epoch* menunjukkan bahwa semakin besar *epoch* maka kinerja sistem akan menurun. Hal tersebut dapat terjadi karena semakin besar nilai *epoch* maka semakin banyak proses pelatihan yang dilakukan oleh sistem, sehingga mengakibatkan sistem mengalami *overfitting*. Oleh karena itu, *epoch* 50 dipilih menjadi nilai yang terbaik karena dapat meningkatkan kinerja sistem

Hasil pengujian yang didapatkan menggunakan parameter terbaik yaitu nilai akurasi sebesar 98,84%, *loss* sebesar 0,1616, presisi sebesar 97,65%, *recall* sebesar 97,65%, dan *F1 Score* sebesar 97,65%. Grafik akurasi dan *loss* model sistem terdapat pada Gambar 12. Adapun *confusion matrix* skenario pengujian terbaik dapat dilihat pada Gambar 13.



GAMBAR 12 (a) Akurasi dan (b) *loss* sistem



GAMBAR 13 *Confusion matrix skenario pengujian terbaik*

V KESIMPULAN

Tugas Akhir ini telah menghasilkan sistem klasifikasi penyakit tumor otak pada citra MRI menggunakan metode *Convolutional Neural Network* dengan arsitektur Alexnet untuk mencapai kinerja sistem yang optimal. Parameter yang digunakan dapat mempengaruhi kinerja sistem, sehingga pengujian harus dilakukan untuk menentukan parameter terbaik pada model sistem yang dirancang. Berdasarkan hasil skenario pengujian dan analisis pengaruh parameter terhadap sistem, dapat disimpulkan bahwa sistem yang dirancang dapat mengklasifikasikan citra

tumor otak ke dalam empat kelas, yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor*. Sistem dapat bekerja secara optimal dengan menggunakan citra masukan berukuran 224x224 piksel, rasio 80% data latih, 10% data validasi, dan 10% data uji, menggunakan *Adam optimizer*, memakai ukuran *learning rate* sebesar 0.0001, *batch* berukuran 8, dan jumlah *epoch* 50.

Ukuran citra 224x224 piksel membuat sistem lebih teliti dalam mempelajari informasi citra. Penggunaan rasio data latih yang besar dapat membuat sistem lebih banyak mempelajari pola citra. *Adam optimizer* menghasilkan kinerja yang optimal pada sistem ini. Nilai *learning rate* 0.0001 menunjukkan bahwa pada sistem ini penggunaan

learning rate yang kecil dapat membuat sistem mencapai titik optimal, dan ukuran *batch* 8 menghasilkan sistem yang stabil. Penggunaan *epoch* 50 menghasilkan kinerja sistem yang optimal dibandingkan dengan penggunaan nilai *epoch* yang lain. Hasil akurasi kinerja sistem adalah sebesar 98,84%, *loss* sebesar 0,1616, presisi sebesar 97,65%, *recall* sebesar 97,65%, dan *F1 Score* sebesar 97,65%.

REFERENSI

- [1] Cancer Support Community and National Brain Tumor Society, *Brain Tumors*. 2019.
- [2] Brunner and Suddart, *Brain Tumors*, 12th ed. Lippincott Williams & Wilkins., 2010.
- [3] The Global Cancer Observatory, *Brain, central nervous system*. 2020.
- [4] S. Khan, H. Rahmani, S. Afaq, A. Shah, and M. Bennamoun, "A Guide to Convolutional Neural Networks for Computer Vision."
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *ImageNet Classif. with Deep Convolutional Neural Networks*, vol. 60, pp. 84–86, 2012.
- [6] A. Hussain and A. Khunteta, "Semantic Segmentation of Brain Tumor from MRI Images and SVM Classification using GLCM Features," pp. 38–39, 2020.
- [7] A. Zainudin *et al.*, *BRAIN TUMOR CLASSIFICATION USING MRI IMAGES WITH K-NEAREST NEIGHBOR METHOD*.
- [8] S. K. Baranwal, K. Jaiswal, K. Vaibhav, A. Kumar, and D. R. Srikantaswamy, "Performance analysis of Brain Tumour Image Classification using CNN and SVM," pp. 537–538, 2020.
- [9] J. Seetha and S. S. Raja, "Brain tumor classification using Convolutional Neural Networks," *Biomed. Pharmacol. J.*, vol. 11, no. 3, pp. 1457–1461, Sep. 2018, doi: 10.13005/bpj/1511.
- [10] Masoud Nickparvar. Brain Tumor MRI Dataset [Data set]. *Kaggle*. 2021. <https://doi.org/10.34740/KAGGLE/DSV/2645886>