

## OPTIMALISASI KLASIFIKASI CITRA MEDIS MENGGUNAKAN CNN DAN ADAM OPTIMIZER DENGAN PARAMETER MINIMUM

Sofyan Pariyasto<sup>1</sup>, Vicky Arfeni Warongan<sup>2</sup>, Suryani<sup>3</sup>

Sekolah Tinggi Ilmu Kesehatan Mitra Sejati, Medan

e-mail: <sup>1</sup>spariyasto@gmail.com, <sup>2</sup>vickyarfeni@gmail.com,  
<sup>3</sup>suryani90harahap@gmail.com

**Abstract:** Research in the field of imaging, especially in medical terms, is expected to have a positive impact on the treatment and diagnosis of diseases in the medical world. Medical image classification is a topic that is often researched, this is indicated by the many national and international journals that discuss this topic. Research on medical image classification using Convolutional Neural Network (CNN) usually focuses on the use of maximum parameters (hyper parameters) to get the best results. However, those that use minimal parameters and the smallest resources are still lacking. Based on the existing problems, it is carried out to obtain optimization in the medical image classification process. The classification of medical images in this study focuses on brain tumor images consisting of three classes, namely meningioma, glioma and pituitary tumor. The approach taken in this study is to use the CNN model and Adaptive Moment Estimation (Adam) Optimizer. The study was conducted by combining the smallest parameters from the Adam Optimizer. The parameters combined are Epoch and Convolution Layer. Where 3 Epoch categories (1,5,10) and 5 convolution layers (1,2,3,4,5) are used. From the tests carried out, the highest accuracy results obtained were 92.8% with epoch parameters of 10 and three convolution layers. Meanwhile, the highest average accuracy was recorded at 90.7% with epoch parameters of 10. The fastest computation time required for model creation was 24.83 seconds, and the lowest CPU resource usage during the model creation process was 16.45%.

**Keywords:** Image Classification, CNN Optimization, Adam Optimizer, Brain Tumor, Minimum Parameters

**Abstrak:** Penelitian dibidang citra khususnya dalam hal medis diharapkan dapat membawa dampak baik bagi penanganan dan diagnosis penyakit dalam dunia medis. Klasifikasi citra medis menjadi topik yang cukup sering diteliti, hal ini ditandai dengan banyaknya jurnal baik nasional maupun internasional yang membahas mengenai topik ini. Penelitian mengenai klasifikasi citra medis menggunakan Convolutional Neural Network (CNN) biasanya berfokus pada penggunaan paramater maksimal (hyper parameter) untuk mendapatkan hasil terbaik. Namun yang menggunakan paramater minimal dan sumber daya terkecil masih belum ada. Berdasarkan permasalahan yang ada maka dilakukan untuk mendapatkan optimalisasi dalam proses kalsifikasi citra medis. Klasifikasi citra medis dalam penelitian ini difokuskan pada citra tumor otak yang terdiri dari tiga kelas yaitu, meningioma, glioma dan pituitary tumor. Pendekatan yang dilakukan dalam penelitian ini adalah menggunakan model CNN dan Adaptive Moment Estimation (Adam) Optimizer. Penelitian dilakukan dengan melakukakn kombinasi paramater terkecil dari Optimizer Adam. Paramater yang dikombinasikan yaitu Epoch dan Lapisan konvolusi. Dimana digunakan 3 kategori Epoch (1,5,10) serta 5 lapisan konvolusi (1,2,3,4,5). Dari pengujian yang dilkaukan didapatkan hasil Akurasi tertinggi yang diperoleh adalah 92,8% dengan parameter epoch 10 dan tiga lapisan konvolusi. Sementara itu, akurasi rata-rata tertinggi tercatat sebesar 90,7% dengan parameter epoch 10. Waktu komputasi tercepat yang diperlukan untuk pembuatan model adalah 24,83 detik, dan penggunaan sumber daya CPU terendah selama proses pembuatan model adalah 16,45%.

**Kata kunci:** Klasifikasi Citra, Optimalisasi CNN, Adam Optimizer, Tumor Otak, Paramater Minimum

## PENDAHULUAN

Penggunaan teknologi dalam bidang kesehatan tentu bukan hal baru, hal ini dibuktikan dengan banyaknya penelitian dibidang medis dengan memanfaatkan kecerdasan buatan. Penelitian mengenai proses klasifikasi citra medis dibidang kesehatan diharapkan dapat membantu proses identifikasi jenis gangguan kesehatan.

Banyak kasus tumor otak yang ada menjadi salah satu perhatian yang cukup serius dalam penelitian ini. Berdasarkan keputusan Menteri Kesehatan Republik Indonesia Nomor: HK.01.07/MENKES/397/2020, tentang pedoman nasional pelayanan kedokteran tata laksana tumor otak, diketahui bahwa Di Amerika dan Eropa, angka penderita tumor otak meningkat dari 17,6/100.000 hingga 22,0 /100.000 penduduk, dengan sekitar 18.500 kasus baru tumor otak primer didiagnosis setiap tahun di Amerika. Kasus ini memiliki tingkat kematian yang relatif tinggi, yaitu 3% untuk tingkat kelangsungan hidup selama 5 tahun (Fileunduhun\_1610423332\_841380, n.d.). Berdasarkan Cancer Council Victoria, Pada tahun 2022, sebanyak 1359 warga Victoria didiagnosis dengan kanker otak dan sistem saraf pusat. Dari jumlah tersebut, 641 di antaranya adalah laki-laki dan 718 perempuan, yang masing-masing mewakili 61% dan 39% dari total diagnosis kanker otak di Victoria (Brain & Central Nervous System Cancer Statistics - Cancer Council Victoria, n.d.). Berdasarkan data National Cancer Institute dari United States, ada sekitar 25.400 kasus baru penderita kangker otak pada tahun 2024. Juga terdapat 18.760 kasus kematian yang disebabkan oleh kanker otak (Brain and Other Nervous System Cancer — Cancer Stat Facts, n.d.).

Penelitian ini bertujuan untuk membantu proses klasifikasi citra tumor otak yang terdiri dari tiga kelas yaitu : meningioma, glioma dan pituitary tumor. Proses klasifikasi dilakukan dengan menggunakan pendekatan model Convolutional Neural Network (CNN). Optimizer yang digunakan dalam penelitian ini adalah Adaptive Moment Estimation (ADAM).

Sudah cukup banyak penelitian yang berkaitan dengan proses klasifikasi citra medis, khususnya yang menggunakan model CNN. Namun, yang membahas mengenai penggunaan paramater minimum dalam optimizer belum ada. Hal ini yang menjadi latar belakang dilakukan penelitian ini. Penggunaan kecerdasan buatan membutuhkan sumber daya yang cukup besar agar bisa berjalan dengan lancar. Hal ini juga menjadi salah satu kendala peneliti yang tidak memiliki sumber daya besar untuk melakukan penelitian dibidang kecerdasan buatan khususnya CNN.

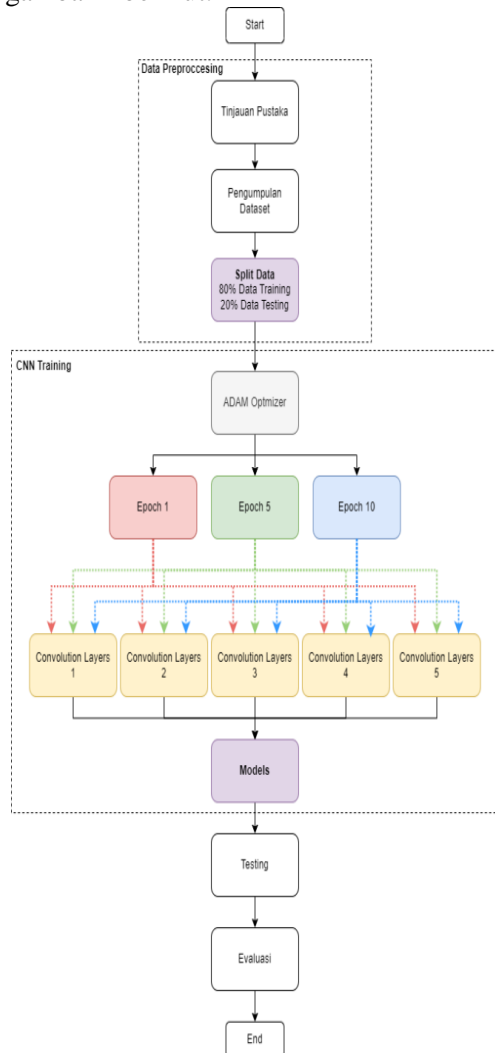
Penggunaan parameter minimum yang dilakukan dalam proses komputasi kecerdasan buatan, membutuhkan sumber daya sekecil mungkin, baik dari sisi penggunaan Random Access Memory (RAM) dan Prosesor. Karena parameter yang digunakan merupakan nilai paling kecil tentu waktu yang dibutuhkan untuk proses komputasi juga lebih sedikit. Baik waktu dalam proses training maupun waktu dalam proses testing. Penggunaan paramater minimum diharapkan dapat diterapkan disemua perangkat dengan spesifikasi minimum, dengan hasil akurasi terbaik.

## METODE

### Tahapan Penelitian

Penelitian ini dilakukan dengan beberapa tahapan dimulai proses *study*

*literature* hingga proses evaluasi hasil penelitian. Tahapan metodologi penelitian yang dilakukan terlihat seperti gambar gambar 1 berikut.



**Gambar 1. Alur proses penelitian yang dilakukan**

Tahapan proses penelitian melalui empat tahapan utama yaitu data *preroccesing*, *CNN training*, *testing* dan Evaluasi.

### Tinjauan Pustaka

Sejak tahun 2006 *deep learning* telah muncul sebagai salah satu cabang *machine learning* dalam *computer vision*. *Deep learning* adalah metode pemrosesan citra menggunakan beberapa lapisan struktur yang terdiri dari beberapa proses transformasi (Cai et al., 2020). Klasifikasi citra medis adalah penelitian

yang dilakukan dengan memanfaatkan kecerdasan buatan untuk membantu proses diagnosis (Kim et al., 2022) (Li et al., 2014) (Deepa & Aruna Devi, 2011; Miranda et al., 2016). Proses klasifikasi memanfaatkan *deep learning* untuk proses identifikasi penyakit berdasarkan ciri khusus yang ada dalam sebuah citra (Zhang et al., 2019). Klasifikasi gambar secara medis diharapkan dapat membantu proses diagnosa penyakit tertentu khususnya yang berakitan dengan citra medis (Yadav & Jadhav, 2019). Citra medis yang digunakan dalam penelitian ini adalah citra medis tumor otak.

Tumor otak merupakan kondisi medis yang dapat membahayakan nyawa (Saleh et al., 2020). Penyakit ini bisa berupa tumor ganas atau jinak (Y. Borole et al., 2015). Ketika sel-sel tumor tumbuh, mereka dapat memberikan tekanan pada tengkorak, yang berpotensi merusak otak (Nalbalwar et al., 2014). Ada dua jenis tumor otak, yaitu tumor otak primer dan sekunder. Tumor otak primer berasal langsung dari jaringan otak dan biasanya bersifat jinak. Sedangkan tumor otak sekunder terjadi akibat penyebaran sel kanker dari organ tubuh lain, seperti paru-paru atau payudara, ke otak. Tumor ini juga dikenal sebagai metastasis otak. Tumor otak dapat menyerang siapa saja, tanpa memandang usia (Tamilselvi et al., 2020).


Ada tiga jenis tumor otak yang menjadi topik utama dalam penelitian ini yaitu, *meningioma*, *glioma* dan *pituitary tumor*. *Meningioma* adalah tumor otak primer (Maggio et al., 2021) yang paling umum terjadi pada orang dewasa (David Delgado-López et al., 2020), mewakili sekitar sepertiga dari seluruh neoplasma intrakranial. Penyakit ini secara umum ditemukan lebih sering terjadi pada wanita (Apra et al., 2018), dengan pengecualian pada penyakit dengan tingkat lebih tinggi yang memiliki kecenderungan pada pria, dan pasien berusia lebih tua (Huntoon et al., 2020).

*Glioma* adalah jenis tumor otak yang berasal dari sel *glial* otak atau sumsum tulang belakang (Bashir Gonbadi

& Khotanlou, 2019) (Herholz et al., 2012; Malmer et al., 2001). Glioma berasal dari sel-sel pendukung yang lengket, yaitu sel glial, yang berfungsi mengelilingi dan membantu kerja sel-sel saraf. Sel *glial* merupakan jenis sel pendukung di otak, yang terdiri dari tiga jenis utama: astrosit, oligodendrosit, dan sel ependimal (Case Report On Brain Tumour (Glioma), n.d.). Tumor hipofisis atau *pituitary tumor* merupakan jenis tumor yang sering ditemukan di antara tumor otak (Pak et al., 2018). Tumor hipofisis adalah tumor yang tidak bersifat kanker. Meskipun demikian, tumor ini bisa menyebabkan masalah serius, seperti kekurangan hormon atau bahkan kehilangan penglihatan permanen akibat produksi hormon yang berlebihan (Masood et al., 2021). Tumor hipofisis adalah jenis tumor di dalam otak yang bersifat jinak dan cukup sering ditemukan, sekitar 10%-15% (Zhan et al., 2015) dari semua tumor di otak. (Chang-Wei et al., 2023; Sun et al., 2022).

### Dataset

Dataset yang digunakan pada penelitian ini adalah *Brain Tumor Image Dataset* (*Brain Tumor Dataset*, n.d.; *Brain Tumor Image Dataset*, n.d.) yang berasal dari kaggle. Dataset terdiri dari 3.064 citra dari total 233 pasien. Dataset terdiri dari citra meningioma sebanyak 708 citra, glioma sebanyak 1426 citra, dan *pituitary tumor* 930 citra. Dataset yang digunakan untuk proses penelitian dipecah menjadi 80% data *training* dan 20% data *testing*.




**Gambar 2. Brain Tumor Image Dataset.**

Dari gambar 2 terlihat tampilan data set yang digunakan yang terdiri dari 3 kelas.

### CNN

*Convolutional Neural Networks* (CNN) adalah model yang dikhususkan untuk pengenalan gambar dan memiliki akurasi tinggi dalam mengklasifikasikan objek dalam gambar (Haar et al., 2023). *Convolutional Neural Networks* mengacu pada penggunaan operasi matematika yang disebut konvolusi. Konvolusi memungkinkan jaringan untuk mempelajari fitur-fitur dalam data masukan dengan cara menggabungkan dan tumpang tindih wilayah-wilayah kecil dari data tersebut. Dengan cara ini, jaringan dapat mengenali pola, meskipun pola tersebut tidak secara langsung dijelaskan dalam data pelatihan (Rguibi et al., 2022). Ilustrasi model CNN terlihat seperti gambar 3 berikut:



**Gambar 3. Ilustrasi model CNN.**

Dalam penelitian ini *Optimizer* yang digunakan dalam proses komputasi adalah *Adam Optimizer*. *Adaptive Moment Estimation (Adam) Optimizer* adalah salah satu algoritma optimisasi yang paling banyak digunakan dalam pelatihan jaringan saraf, termasuk dalam *Convolutional Neural Networks* (CNN). Adam adalah algoritma yang membantu memperbarui bobot jaringan saraf dengan cara yang lebih cerdas dan efisien (Kumar Pentapati, n.d.; Sen & Ozkurt, 2020; Tang et al., 2024). Algoritma ini bekerja dengan menghitung dua nilai penting: yang pertama adalah rata-rata gradien, yang membantu membuat pembaruan lebih konsisten, dan yang kedua adalah rata-rata kuadrat gradien, yang menyesuaikan pembaruan berdasarkan seberapa besar gradien tersebut. Dengan cara ini, Adam dapat menyesuaikan pembaruan untuk setiap parameter secara

terpisah, mengurangi fluktuasi, dan mempercepat proses pembelajaran. Selain itu, Adam juga melakukan penyesuaian awal agar pembaruan tidak terlalu kecil, membuatnya lebih stabil dan cepat dalam belajar. *Optimizer* Adam juga cukup baik jika dibandingkan dengan *optimizer* lainnya dalam *deep learning* (Loganathan & Latha, 2024).

Adam memiliki parameter yang digunakan dalam proses komputasi (Kah Meng et al., 2023) terlihat seperti pada tabel 1 berikut.

**Tabel 1. Paramater Adam**

No	Paramater
1	Learning Rate ( $\eta$ atau lr)
2	Beta 1 ( $\beta_1$ ) dan Beta 2 ( $\beta_2$ )
3	Epsilon ( $\epsilon$ )
4	Weight Decay (atau L2 Regularization)
5	batch
6	Epoch
7	Lapisan konvolusi

Proses optimalisasi yang dilakukan dalam penelitian ini adalah dengan menyesuaikan nilai parameter *Epoch* dengan 10 nilai terkecil untuk mendapatkan hasil terbaik. Juga dilakukan penyesuaian terhadap jumlah lapisan konvolusi dengan nilai dari 1 sampai dengan 5 lapisan konvolusi.

Sementara nilai pada parameter selain *Epoch* dan Lapisan konvolusi disesuaikan dengan nilai berikut ini (tabel 2).

**Tabel 2. Paramater yang digunakan**

Parameter	Value
Learning Rate ( $\eta$ atau lr)	0.01
Beta 1 ( $\beta_1$ ) dan Beta 2 ( $\beta_2$ )	0.9 dan 0.999
Epsilon ( $\epsilon$ )	1,00E-08
Weight Decay (atau L2 Regularization)	0
batch	64

Hasil dari proses komputasi yang dilakukan adalah *model.pth*. *Model.pth* adalah file yang digunakan untuk menyimpan model yang telah dilatih

dalam format yang dapat digunakan kembali di kemudian hari. "PTH" merujuk pada ekstensi file untuk *PyTorch*, sebuah pustaka machine learning yang sangat populer. File ini biasanya berisi bobot dan parameter dari model jaringan saraf yang telah dilatih, sehingga model tersebut bisa dimuat kembali tanpa perlu melatihnya dari awal.

### Evaluasi Hasil Penelitian

Untuk mengetahui kinerja dari model yang dihasilkan maka dilakukan pengujian dengan menggunakan metode *confusion matrix*. Pengujian dengan *confusion matrix* dilakukan untuk mengetahui nilai presisi, akurasi, recall dan F1-Scorenya. *Confusion matrix* biasanya disusun dalam bentuk tabel yang terdiri dari dua baris dan dua kolom (Deng et al., 2016; Sathyanarayanan, 2024) seperti pada tabel 3 berikut.

**Tabel 3. Confusion matrix**

	Prediksi Positif (P)	Prediksi Negatif (N)
Aktual Positif (P)	True Positive (TP)	False Negative (FN)
Aktual Negatif (N)	False Positive (FP)	True Negative (TN)

*True Positive (TP)* adalah Jumlah gambar yang benar-benar termasuk dalam kelas tertentu dan berhasil diprediksi dengan benar oleh model. *False Positive (FP)* adalah jumlah gambar yang diprediksi termasuk dalam kelas tertentu, tetapi sebenarnya termasuk kelas lain. *False Negative (FN)* adalah jumlah gambar yang benar-benar termasuk dalam kelas tertentu, tetapi diprediksi sebagai kelas lain. *True Negative (TN)* adalah gambar yang benar-benar tidak termasuk dalam kelas tertentu dan diprediksi dengan benar (Valero-Carreras et al., 2023).

Akurasi mengukur seberapa sering model membuat prediksi yang benar maka persamaan yang digunakan terlihat seperti persamaan 1 berikut.

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

Akurasi memberikan gambaran umum tentang kinerja model.

Presisi mengukur berapa banyak prediksi positif yang benar-benar positif. Dalam klasifikasi gambar, ini menunjukkan berapa banyak gambar yang diprediksi benar dan bernilai benar. Persamaan *precision* terlihat seperti persamaan 2 berikut.

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

*Recall* (Sensitivitas) digunakan untuk mengukur seberapa banyak gambar yang benar-benar positif yang berhasil diprediksi dengan benar oleh model. Ini juga dikenal dengan *True Positive Rate* (TPR). Persamaan *recall* terlihat seperti persamaan 3 berikut.

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

*F1-Score* Merupakan rata-rata harmonis dari *precision* dan *recall*. *F1-*

*Score* memberikan gambaran umum yang lebih baik ketika kita membutuhkan keseimbangan antara keduanya. Persamaan *F1-Score* terlihat seperti persamaan 4 berikut.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

## HASIL DAN PEMBAHASAN

Pengujian dilakukan dengan tiga tahapan *epochs* dan lima lapisan layer konvolusi. Sehingga kombinasi dari total pengujian adalah  $3 \times 5 = 15$  pengujian berbeda.

### Pengujian dengan Epoch 1

Pengujian pertama dilakukan dengan paramater *epoch* bernilai 1 dan dikombinasikan dengan masing-masing lapisan konvolusi. Sehingga terdapat 5 kombinasi pengujian. Hasil dari pengujian yang dilakukan terlihat seperti pada tabel 4 berikut.

**Tabel 4. Hasil Pengujian dengan Epoch 1**

Convolution Layers	Support	Precision	Recall	F1-score	Accuracy
1	612	0,77	0,77	0,77	77,3
2	612	0,81	0,75	0,75	75,2
3	612	0,73	0,74	0,72	73,9
4	612	0,53	0,62	0,53	61,6
5	612	0,55	0,67	0,59	67

Waktu yang dibutuhkan serta persentase penggunaan CPU saat proses komputasi berlangsung terlihat pada tabel 5 berikut.

**Tabel 5. Waktu dan Penggunaan CPU dari Epoch 1**

Convolution Layers	Time (seconds)	CPU Usage (%)
1	27,49	16,45
2	25,11	24,9
3	25,67	25,7
4	24,83	27,55
5	26,36	27,25

### Pengujian dengan Epoch 5

Pengujian pertama dilakukan dengan paramater *epoch* bernilai 5 dan

dikombinasikan dengan masing-masing lapisan konvolusi. Sehingga terdapat 5 kombinasi pengujian. Hasil dari pengujian

yang dilakukan terlihat seperti pada tabel 6 berikut.

**Tabel 6. Hasil Pengujian dengan Epoch 5**

Convolution Layers	Support	Precision	Recall	F1-score	Accuracy
1	612	0,88	0,89	0,88	88,6
2	612	0,86	0,86	0,86	85,9
3	612	0,86	0,86	0,86	86,3
4	612	0,83	0,83	0,82	82,5
5	612	0,82	0,82	0,82	81,7

Waktu yang dibutuhkan serta persentase penggunaan CPU saat proses

komputasi berlangsung terlihat pada tabel 7 berikut.

**Tabel 7. Waktu dan Penggunaan CPU dari Epoch 5**

Convolution Layers	Time (seconds)	CPU Usage (%)
1	116,02	27,45
2	115,46	26,95
3	136,98	24,7
4	117,15	27,2
5	120,4	27,3

#### **Pengujian dengan Epoch 10**

Pengujian pertama dilakukan dengan paramater *epoch* bernilai 10 dan dikombinasikan dengan masing-masing

lapisan konvolusi. Sehingga terdapat 5 kombinasi pengujian. Hasil dari pengujian yang dilakukan terlihat seperti pada tabel 8 berikut.

**Tabel 8. Hasil pengujian dengan Epoch 10**

Convolution Layers	Support	Precision	Recall	F1-score	Accuracy
1	612	0,9	0,89	0,89	89,1
2	612	0,89	0,89	0,89	88,9
3	612	0,93	0,93	0,93	92,8
4	612	0,94	0,93	0,93	92,8
5	612	0,9	0,9	0,9	89,9

Waktu yang dibutuhkan serta persentase penggunaan Cpu saat proses

komputasi berlangsung terlihat pada tabel 9 berikut.

**Tabel 9. Waktu dan Penggunaan CPU dari Epoch 10**

Convolution Layers	Time (seconds)	CPU Usage (%)
1	116,02	27,45
2	115,46	26,95
3	136,98	24,7
4	117,15	27,2
5	120,4	27,3

#### **Evaluasi Hasil Penelitian**

Dari penelitian yang dilakukan diambil nilai akurasi tertinggi dari

masing-masing *epoch* terlihat seperti pada tabel 10 berikut.

**Tabel 10. Akurasi Tertinggi dari Masing-masing Epoch**

Epoch	Convolution Layers	Precision	Recall	F1-score	Accuracy
1	1	0,77	0,77	0,77	77,3
5	1	0,88	0,89	0,88	88,6
10	3	0,93	0,93	0,93	92,8

Dari tabel 10 terlihat akurasi *epoch* 1 adalah 77,3. Akurasi *epoch* 5 adalah 88,6 dan ekurasi *epoch* 10 adalah 92,8.

Dengan paramater minimum dari CNN dan Adam *optimizer* dapat dilihat bahwa akurasi masih cukup tinggi diatas 75%.

**Tabel 11. Akurasi Rata-rata dari Masing-masing Epoch**

Epoch	Precision	Recall	F1-score	Accuracy
1	0,678	0,71	0,672	71
5	0,85	0,852	0,848	85
10	0,912	0,908	0,908	90,7

Ditinjau dari rata-rata akurasi pada masing-masing *epoch*, pada tabel 11 terlihat akurasi *epoch* 1 adalah 71. Akurasi *epoch* 5 adalah 85 dan ekurasi *epoch* 10 adalah 90.7. Dengan paramater minimum dari CNN dan Adam *optimizer* dapat dilihat bahwa akurasi rata-rata masih cukup tinggi diatas 70%.

## SIMPULAN

Penelitian yang dilakukan menghasilkan kesimpulan bahwa dengan paramater minimum masih bisa dihasilkan akurasi yang cukup baik. Nilai akurasi tertinggi yang didapatkan adalah 92.8 dengan paramater *epoch* 10 dan lapisan konvolusi 3. Sementara nilai akurasi rata-rata tertinggi adalah 90,7 dengan paramater *epoch* 10. Waktu komputasi tercepat yang dibutuhkan untuk melakukan proses pembuatan model adalah 24,83 detik. Dan penggunaan sumber daya CPU minimum untuk proses pembuatan model adalah 16.45%. tentu dengan adanya paramater minimum memungkinkan untuk melakukan proses komputasi dengan sumber daya terbatas dan waktu komputasi yang singkat namun memberikan hasil yang cukup baik.

## DAFTAR PUSTAKA

- Apra, C., Peyre, M., & Kalamarides, M. (2018). Current treatment options for meningioma. In *Expert Review of Neurotherapeutics* (Vol. 18, Issue 3, pp. 241–249). Taylor and Francis Ltd. <https://doi.org/10.1080/14737175.2018.1429920>
- BashirGonbadi, F., & Khotanlou, H. (2019). Glioma Brain Tumors Diagnosis and Classification in MR Images based on Convolutional Neural Networks. IEEE.
- Brain & Central Nervous System Cancer Statistics - Cancer Council Victoria. (n.d.). Retrieved December 22, 2024, from <https://www.cancervic.org.au/cancer-information/statistics/brain-and-central-nervous-system.html>
- Brain and Other Nervous System Cancer — Cancer Stat Facts. (n.d.). Retrieved December 22, 2024, from <https://seer.cancer.gov/statfacts/html/brain.html>
- brain tumor dataset. (n.d.). Retrieved December 22, 2024, from [https://figshare.com/articles/dataset/brain\\_tumor\\_dataset/1512427/5](https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5)
- Brain Tumor Image Dataset. (n.d.). Retrieved December 22, 2024, from <https://www.kaggle.com/datasets/denizkavil/brain-tumor>
- Cai, L., Gao, J., & Zhao, D. (2020). A review of the application of deep learning in medical image

- classification and segmentation. *Annals of Translational Medicine*, 8(11), 713–713. <https://doi.org/10.21037/atm.2020.0244>
- Case Report On Brain Tumour (Glioma). (n.d.).
- Chang-Wei, H., Li, Y. B., Han, X. Y., Yin, G. F., & Wang, X. R. (2023). To explore the change of motor cognitive function in pituitary tumor rats after operation. *Computer Assisted Surgery*, 28(1). <https://doi.org/10.1080/24699322.2023.2198099>
- David Delgado-López, P., Cubo-Delgado, E., & Javier González-Bernal, J. (2020). A Practical Overview on the Molecular Biology of Meningioma. <https://doi.org/10.1007/s11910-020-01084-w/Published>
- Deepa, S., & Aruna Devi, B. (2011). A survey on artificial intelligence approaches for medical image classification. *Indian Journal of Science and Technology*, 4(11). <http://www.indjst.org>
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*, 340–341, 250–261. <https://doi.org/10.1016/j.ins.2016.01.033>
- fileunduhan\_1610423332\_841380. (n.d.).
- Haar, L. V., Elvira, T., & Ochoa, O. (2023). An analysis of explainability methods for convolutional neural networks. *Engineering Applications of Artificial Intelligence*, 117. <https://doi.org/10.1016/j.engappai.2022.105606>
- Herholz, K., Langen, K. J., Schiepers, C., & Mountz, J. M. (2012). Brain tumors. In *Seminars in Nuclear Medicine* (Vol. 42, Issue 6, pp. 356–370). W.B. Saunders. <https://doi.org/10.1053/j.semnuclmed.2012.06.001>
- Huntoon, K., Toland, A. M. S., & Dahiya, S. (2020). Meningioma: A Review of Clinicopathological and Molecular Aspects. In *Frontiers in Oncology* (Vol. 10). Frontiers Media S.A. <https://doi.org/10.3389/fonc.2020.579599>
- Kah Meng, L., Jia Xin, L., Hooi Yi, H., Arabee Abdul Salam, Z., & Bo Wei, N. (2023). A Machine Learning Approach for Face Mask Detection System with AdamW Optimizer. In *Journal of Applied Technology and Innovation* (Vol. 7, Issue 3).
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). Transfer learning for medical image classification: a literature review. In *BMC Medical Imaging* (Vol. 22, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12880-022-00793-7>
- Kumar Pentapati, H. (n.d.). Advanced Adam Optimization based Dilated Convolution Network with Feature Fusion for Speaker Identification. <https://ssrn.com/abstract=4736349>
- Li, Q., Cai, W., Wang, X., Zhou, Y., Dagan Feng, D., & Chen, M. (2014). Medical Image Classification with Convolutional Neural Network. *IEEE*.
- Loganathan, R., & Latha, S. (2024). The Empirical Comparison of Deep Neural Network Optimizers for Binary Classification of OCT Images. In *Library Progress International* (Vol. 44, Issue 3). [www.bpasjournals.com](http://www.bpasjournals.com)
- Maggio, I., Franceschi, E., Tosoni, A., Nunno, V. Di, Gatto, L., Lodi, R., & Brandes, A. A. (2021). Meningioma: Not always a benign tumor. A review of advances in the treatment of meningiomas. *CNS Oncology*, 10(2). <https://doi.org/10.2217/cns-2021-0003>
- Malmer, B., Iselius, L., Holmberg, E., Collins, A., Henriksson, R., & Grönberg, H. (2001). Genetic epidemiology of glioma. *British Journal of Cancer*, 84(3), 429–434.

- <https://doi.org/10.1054/bjoc.2000.1612>
- Masood, M., Nazir, T., Nawaz, M., Mehmood, A., Rashid, J., Kwon, H. Y., Mahmood, T., & Hussain, A. (2021). A novel deep learning method for recognition and classification of brain tumors from mri images. *Diagnostics*, 11(5). <https://doi.org/10.3390/diagnostics11050744>
- Miranda, E., Aryuni, M., & Irwansyah, E. (2016). A Survey of Medical Image Classification Techniques. *IEEE*.
- Nalbalwar, R., Majhi, U., Patil, R., & Gonge, P. (2014). Detection of Brain Tumor by using ANN. *International Journal of Research in Advent Technology*, 2(4).
- Pak, Y., Yang, X., Kim, Y., Jong, C., Kim, H., Lee, N., Kim, S., & Kim, Y. (2018). A study on sublabial transsphenoidal treatment of pituitary tumor under microscope with aid of endoscope. *Chinese Neurosurgical Journal*, 4(1). <https://doi.org/10.1186/s41016-018-0130-y>
- Rguibi, Z., Hajami, A., Zitouni, D., Elqaraoui, A., & Bedraoui, A. (2022). CXAI: Explaining Convolutional Neural Networks for Medical Imaging Diagnostic. *Electronics (Switzerland)*, 11(11). <https://doi.org/10.3390/electronics11111775>
- Saleh, A., Sukaik, R., & Abu-Naser, S. S. (2020). Brain tumor classification using deep learning. *Proceedings - 2020 International Conference on Assistive and Rehabilitation Technologies, ICareTech 2020*, 131–136. <https://doi.org/10.1109/iCareTech49914.2020.00032>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 4023–4031. <https://doi.org/10.53555/AJBR.v27i4.S.4345>
- Sen, S. Y., & Ozkurt, N. (2020, October 15). Convolutional Neural Network Hyperparameter Tuning with Adam Optimizer for ECG Classification. *Proceedings - 2020 Innovations in Intelligent Systems and Applications Conference, ASYU 2020*. <https://doi.org/10.1109/ASYU50717.2020.9259896>
- Sun, X., Huo, L., Wang, X., Zhang, C., & Zhao, A. (2022). Comprehensive clinical analysis of patients with primary malignant tumor of pituitary gland: A population-based study. *Frontiers in Surgery*, 9. <https://doi.org/10.3389/fsurg.2022.933168>
- Tamilselvi, R., Nagaraj, A., Beham, M. P., & Sandhiya, M. B. (2020, February 1). BRAMSIT: A Database for Brain Tumor Diagnosis and Detection. *2020 6th International Conference on Bio Signals, Images, and Instrumentation, ICBSII 2020*. <https://doi.org/10.1109/ICBSII49132.2020.9167530>
- Tang, Q., Shpilevskiy, F., & Lécuyer, M. (2024). DP-AdamBC: Your DP-Adam Is Actually DP-SGD (Unless You Apply Bias Correction). [www.aaai.org](http://www.aaai.org)
- Valero-Carreras, D., Alcaraz, J., & Landete, M. (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers and Operations Research*, 152. <https://doi.org/10.1016/j.cor.2022.106131>
- Y. Borole, V., S. Nimbhore, S., & S. Kawthekar, Dr. S. (2015). Image Processing Techniques for Brain Tumor Detection: A Review. [www.ijettcs.org](http://www.ijettcs.org)
- Yadav, S. S., & Jadhav, S. M. (2019). Deep convolutional neural network based medical image classification for disease diagnosis. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0276-2>
- Zhan, R., Li, X., & Li, X. (2015). Endoscopic Endonasal

Transsphenoidal Approach for Apoplectic Pituitary Tumor: Surgical Outcomes and Complications in 45 Patients. *Journal of Neurological Surgery, Part B: Skull Base*, 77(1), 54–60. <https://doi.org/10.1055/s-0035-1560046>

Zhang, J., Xie, Y., Wu, Q., & Xia, Y. (2019). Medical image classification using synergic deep learning. *Medical Image Analysis*, 54, 10–19. <https://doi.org/10.1016/j.media.2019.02.010>