

***Deep Learning* untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet**

WAHYUNI RIZKY PERDANI, RITA MAGDALENA, NOR KUMALASARI CAECAR PRATIWI

Fakultas Teknik Elektro, Universitas Telkom, Indonesia
Email: wahyunirizkyper@gmail.com

Received 23 September 2021 | *Revised* 18 Oktober 2021 | *Accepted* 17 November 2021

ABSTRAK

Glaukoma merupakan kerusakan yang terjadi pada saraf mata yang disebabkan oleh meningkatnya tekanan di bola mata. Glaukoma dapat menyebabkan penderitanya mengalami kebutaan permanen. Data dari WHO, jumlah orang yang diperkirakan menjadi buta akibat glaukoma primer adalah 4,5 juta. Penilaian klasifikasi tingkatan glaukoma oleh ophthalmologist menggunakan nilai CDR (Cup to Disc Ratio). Maka dari itu, dibuat sistem yang dapat digunakan dalam mengklasifikasikan glaukoma melalui citra fundus mata dengan menggunakan metode CNN (Convolutional Neural Network) dengan arsitektur EfficientNet. Klasifikasi glaukoma dibagi menjadi 5 kelas, yaitu deep, early, moderate, OHT dan normal. Citra mata yang digunakan didapatkan dari dataset RimOne r1. Penelitian ini mencari sistem dengan performansi terbaik. Model yang mendapatkan parameter performansi terbaik adalah citra dengan hyperparameter optimizer Adamax, learning rate 0,001, epoch 20, dan batch size 32. Akurasi, presisi, recall, dan F1-Score masing-masing mencapai 1,0000.

Kata kunci: *Glaukoma, Convolutional Neural Network (CNN), EfficientNet*

ABSTRACT

Glaucoma is the optic nerve damage caused by increasing pressure on the eyeball. Glaucoma can cause patients to encounter permanent blindness. According to WHO data, the number of people estimated to be blind from primary glaucoma is 4,5 million. Evaluation of glaucoma grade classification by ophthalmologist uses CDR (Cup to Disc Ratio) value. Therefore, a system has been created that can be used to classify glaucoma through eye fundus images using the CNN (Convolutional Neural Network) method with EfficientNet architecture. Glaucoma is classified into 5 classes, namely deep, early, moderate, OHT and normal. The used eye image is obtained from the RimOne r1 dataset. This research is looking for a system with the best performance. The model that got the best performance parameters with the hyperparameter optimizer Adamax, learning rate 0,001, epoch 20, and batch size 32. Accuracy, precision, recall, and F1-Score each reached 1,0000.

Keywords: *Glaucoma, Convolutional Neural Network (CNN), EfficientNet*

1. PENDAHULUAN

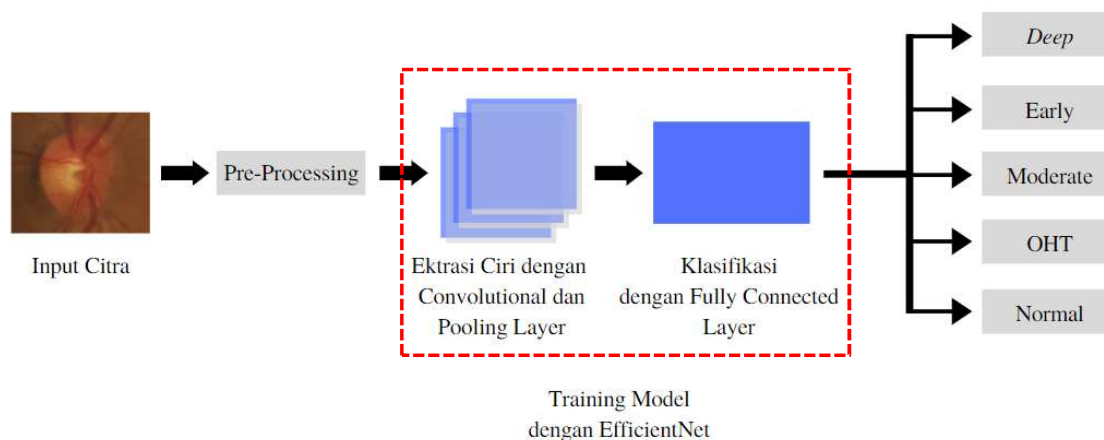
Glaukoma merupakan kerusakan yang terjadi pada saraf mata yang disebabkan oleh meningkatnya tekanan di bola mata. Gangguan sistem aliran cairan mata dapat mengakibatkan meningkatnya tekanan pada bola mata (**Nugraha, dkk, 2020**). Terjadinya pengeluaran cairan secara terus-menerus di depan ruang mata, penyumbatan fisik dan akibat adanya penyempitan pada akar iris mata dialami oleh penderita glaukoma. Glaukoma sering muncul tanpa gejala. Penderita glaukoma pada tahap awal sering tidak menyadari hingga penderitanya mengalami kerusakan penglihatan mata lebih lanjut. Glaukoma dapat menyebabkan penderitanya mengalami kebutaan permanen. Data dari WHO, jumlah orang yang diperkirakan menjadi buta akibat glaukoma primer adalah 4,5 juta, terhitung lebih sedikit dari dua belas persen dari semua kebutaan global (**Rayungsista, 2018**). Berdasarkan tingkatannya glaukoma memiliki tiga tingkatan, yaitu *early*, *moderate* dan *deep (advanced)*. Penilaian klasifikasi tingkatan glaukoma oleh *ophthalmologist* menggunakan nilai CDR (*Cup to Disc Ratio*), yaitu penilaian glaukoma didasarkan pada perbandingan rasio area cakram dan cangkir optik. Pada mata normal nilai CDR kurang dari 0,5 (**Padaria, dkk, 2015**). Dalam melakukan deteksi glaukoma biasanya dokter spesialis mata melakukan pengamatan langsung dari citra fundus retina mata dan untuk melakukan perhitungan nilai CDR membutuhkan banyak waktu karena masih dilakukan secara manual dan menggunakan perangkat yang relatif mahal serta jumlahnya masih terbatas. Dengan dilakukannya deteksi, klasifikasi, dan penanganan sejak dini dapat membantu penderita dalam mengurangi kerusakan mata yang lebih parah.

Penelitian sebelumnya yang dilakukan oleh Radia Touahri, Nabih Azizi, Nacer Eddine, dan Ouided Moumene mengusulkan tentang *a comparative study of convolutional neural network and twin SVM for automatic glaucoma diagnosis*. Dari hasil penelitian dengan menggunakan 300 gambar yang terdiri dari 150 gambar mata penderita glaukoma dan 150 gambar mata normal diperoleh akurasi dengan metode CNN 0,972 dan untuk TWSVM 0,881 (**Touahri, dkk, 2018**). Hal tersebut membuktikan bahwa deteksi glaukoma dengan CNN 3 *layer* merupakan metode yang lebih baik dibandingkan dengan TWSVM. Penelitian lainnya dilakukan oleh Arkaja Saxena, Abhilasha Vyas, Lokesh Parashar, dan Upendra Singh yang mengusulkan *a glaucoma detection using convolutional neural network*. Penelitian ini menggunakan arsitektur *deep learning* CNN dengan 6 lapisan dan menggunakan 2 dataset, yaitu dataset ORIGA terdiri dari 168 gambar glaukoma dan 482 gambar normal fundus dan dataset SCES yang terdiri dari 46 gambar glaukoma dan 1676 gambar normal fundus. Nilai AUC yang diperoleh dalam mengklasifikasikan pola yang diamati pada mata penderita glaukoma dan fundus normal, yaitu 0,822 (dataset ORIGA) dan 0,882 (dataset SCES) (**Saxena, dkk, 2020**). Selain itu, penelitian lain juga dilakukan oleh Ali Serener, Sertan Serte yang mengusulkan *transfer learning for early and advanced glaucoma detection with convolutional neural network*. Dataset yang digunakan, yaitu *Public Image Dataset* berjumlah 1544 gambar yang terdiri dari 788 gambar (normal), 289 gambar (*early glaucoma*), 467 gambar (*advanced glaucoma*) dan dataset Rim-One berjumlah 158 gambar yang terdiri dari, 118 gambar (normal), 12 gambar (*early glaucoma*), 14 gambar (*moderate glaucoma*), dan 14 gambar (*advanced glaucoma/deep glaucoma*). Dengan menggunakan Resnet50 memperoleh hasil untuk *early glaucoma* dengan akurasi 0,90, sensitivitas 0,42, spesifisitas 0,94 dan area di bawah kurva ROC adalah 0,84 dan *advanced glaucoma* akurasi 0,86, sensitivitas 0,21, spesifisitas 0,93 dan area di bawah kurva ROC adalah 0,74. Sedangkan, dengan menggunakan GoogLeNet memperoleh hasil untuk *early glaucoma* dengan akurasi 0,91, sensitivitas 0,17, spesifisitas 0,98 dan area di bawah kurva ROC adalah 0,91 dan *advanced glaucoma* akurasi 0,85, sensitivitas 0,29, spesifisitas 0,91 dan area di bawah kurva ROC adalah 0,75. Dari penelitian tersebut dihasilkan bahwa GoogLeNet lebih baik dalam klasifikasi *early glaucoma* dan *advanced glaucoma* (**Serener, dkk, 2019**).

Dari penelitian diatas, penelitian pertama hanya dapat membedakan mata penderita glaukoma dan mata normal dengan metode CNN 3 *layer* lebih baik daripada TWSVM. Pada penelitian kedua, dapat membedakan mata glaukoma dan fundus normal saja dengan menggunakan *deep learning* CNN 6 lapisan. Sedangkan pada penelitian ketiga, hanya dapat membedakan glaukoma ke dalam 2 kelas, yaitu *early glaucoma* dan *advanced glaucoma*. Berdasarkan penelitian tersebut, maka penelitian ini dibuat untuk melengkapi kekurangan dari sistem model diatas. Sistem yang dibuat merupakan klasifikasi 5 kelas glaukoma, yang terdiri dari *early, moderate, deep, OHT (Hipertensi Okular)*, dan disertai dengan klasifikasi mata normal dengan mengimplementasikan metode *deep learning Convolutional Neural Network (CNN)* dengan arsitektur EfficientNet. Arsitektur EfficientNet mencapai nilai akurasi yang lebih tinggi dibandingkan arsitektur CNN lain. Selain itu, EfficientNet melakukan penskalaan lebih efisien dengan menyeimbangkan kedalaman, lebar, dan resolusi yang dapat membantu dalam meningkatkan kinerja agar lebih baik.


2. METODE PENELITIAN

Tujuan dari penelitian ini adalah mengimplementasikan sistem yang dapat mengklasifikasikan glaukoma ke dalam lima kelas, yaitu *deep, early, moderate, OHT* dan normal. Berikut ini adalah blok diagram sistem secara keseluruhan.



Gambar 1. Blok Diagram Sistem

Citra *input* yang digunakan dalam penelitian ini adalah dataset Rim-One r1. Dataset yang digunakan berbentuk gambar RGB dari fundus retina mata memiliki ukuran pixels berbeda-beda dengan format *file* BMP. Dataset ini didapatkan *dari website Medical Image Analysis Group* Dataset terdiri dari 5 kelas dengan total gambar 169 citra yang terdiri dari, glaukoma tipe *deep* 14 citra, tipe *early* 12 citra, tipe *moderate* 14 citra, tipe OHT 11 citra, dan mata normal 118 citra (Fumero, dkk, 2011). Akan tetapi karena jumlah gambar antar kelas tidak seimbang dilakukan proses augmentasi. Proses augmentasi dilakukan untuk menambahkan jumlah data citra dengan memodifikasi gambar citra, misalnya melakukan rotasi gambar, *flip* gambar, dan *zoom* (Hussain, dkk, 2017). Setelah dilakukan augmentasi pada dataset diperoleh total data citra keseluruhan adalah 1815 citra, yang terdiri dari 363 gambar untuk glaukoma tipe *deep*, 363 citra untuk tipe *early*, 363 citra untuk tipe *moderate*, 363 citra untuk tipe OHT, dan 363 citra untuk mata normal. Gambar 2 merupakan contoh dari *input* citra dari setiap kelas dari dataset yang digunakan.



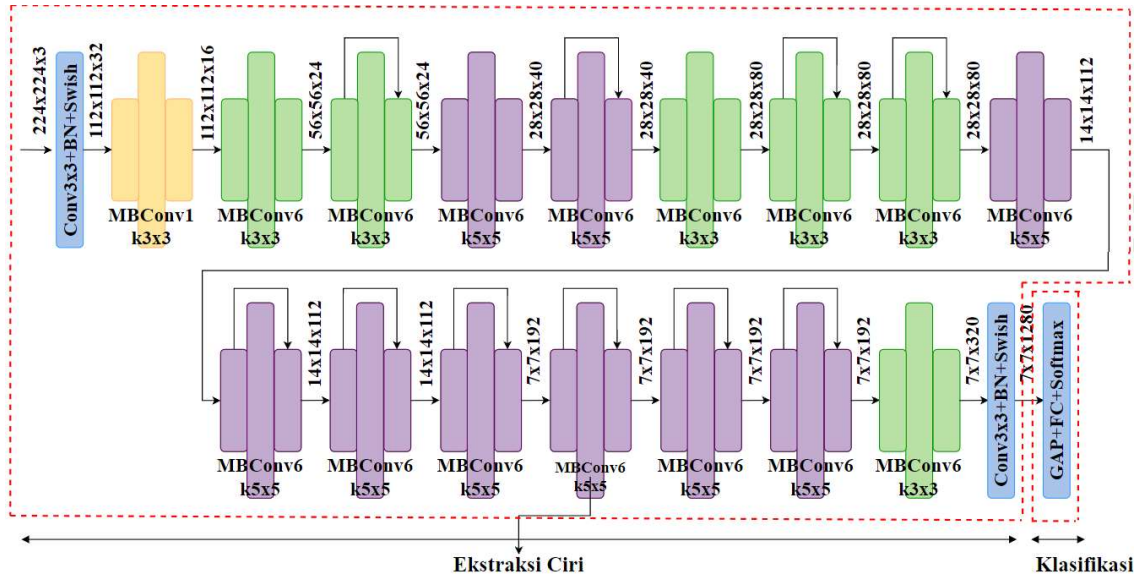
Gambar 2. Glaukoma Tipe Deep (a), Early (b), Moderate (c), OHT (d), dan Fundus Mata Normal (e)

Sebelum masuk ke dalam metode *deep learning* gambar yang digunakan sebagai *input* citra di *resize* terlebih dahulu. *Resize* citra adalah proses yang dilakukan untuk mengubah ukuran citra. Ukuran citra dapat diubah secara *upsized* dan *downsize*. Pada penelitian ini digunakan *resize* citra dengan cara *downsize*. *Downsize* dilakukan dengan mengubah ukuran citra dengan menurunkan jumlah *pixels* serta menghilangkan sebagian informasi dari citra sehingga menghasilkan citra dengan ukuran yang lebih kecil (Suryansah, dkk, 2020). Tujuan dilakukan *resize* untuk menyamakan ukuran citra yang berbeda-beda.

Sistem model yang digunakan pada penelitian ini adalah EfficientNet. EfficientNet menggunakan konvolusi *depthwise* dan *pointwise*. Pada EfficientNet terdapat tiga dimensi penskalaan, yaitu kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) (Kizrak, dkk, 2020). Citra *input* glaukoma yang telah dilakukan *resize* akan dijadikan masukan untuk model EfficientNet. Secara umum model EfficientNet memperoleh hasil akurasi yang tinggi dan performansi yang lebih baik dibandingkan dengan model CNN yang lainnya, mengurangi ukuran parameter dan FLOPS yang optimal (Tan, dkk, 2019). EfficientNet terdiri dari 7 blok. Tiap blok terdiri dari sub-blok yang beragam. EfficientNet menggunakan koefisien gabungan ϕ untuk menskalakan lebar, kedalaman, dan resolusi jaringan secara seragam. Notasi yang digunakan untuk kedalaman, lebar, resolusi terdapat pada Persamaan (1) sampai (3) berikut ini:

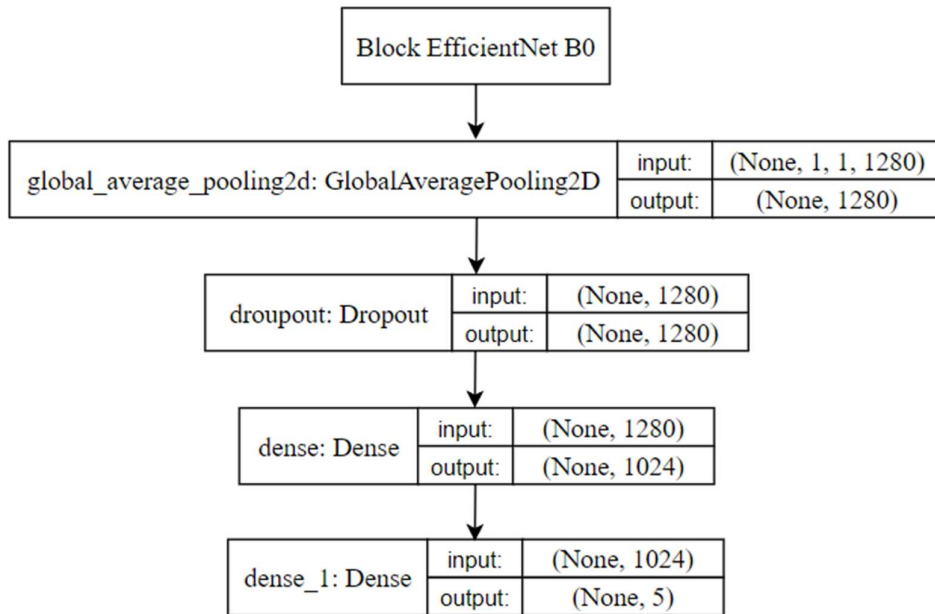
- a. Kedalaman $d = \alpha^\phi$ (1)
 - b. Lebar $w = \beta^\phi$ (2)
 - c. Resolusi $r = \gamma^\phi$ s.t $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$ (3)
- $\alpha \geq 1, \beta \geq 1, \gamma \geq 1$

Dimana α, β, γ adalah konstanta yang dapat ditentukan dengan pencarian grid terkecil. ϕ adalah koefisien yang ditentukan pengguna dalam mengontrol berapa banyak sumber daya yang tersedia untuk penskalaan model. Sedangkan, α, β, γ untuk menentukan bagaimana cara menentukan sumber daya tambahan untuk kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*). Pada peneitian ini penulis menggunakan jaringan dasar EfficientNet-B0. Berikut ini Gambar 3 yang merupakan model EfficientNet-B0 yang digunakan (Alhichri, dkk, 2021).



Gambar 3. Model EfficientNet-B0

Dalam blok EfficientNet-B0 berisi *layer* CNN. Citra *input* yang merupakan citra masukan masuk ke lapisan konvolusi yang merupakan lapisan pertama pada CNN. Lapisan *Pooling* memiliki fungsi untuk mengurangi ukuran spasial dari representasi secara progresif, mengurangi jumlah parameter, dan mengontrol *overfitting* (Kurian, dkk, 2020). Kemudian terdapat aktivasi ReLU yang berperan sebagai fungsi aktivasi yang membuat semua nilai piksel yang bernilai negatif menjadi nol. Setelah itu terdapat *flatten* yang digunakan untuk mengubah citra multidimensi menjadi 1 dimensi agar dapat memasuki lapisan *fully connected*. Lapisan *fully connected* mempunyai koneksi yang terhubung penuh pada semua aktivasi di *layer* sebelumnya (Yu, dkk, 2019).



Gambar 4. Usulan Model EfficientNet-B0

Kemudian terdapat fungsi *softmax* yang digunakan untuk menghitung probabilitas dari tiap kelas yang kemudian kelas dengan probabilitas tertinggi dijadikan hasil prediksi untuk mengklasifikasikan glaukoma ke dalam 5 kelas (**Ghosh, dkk, 2019**). Penelitian ini menggunakan usulan model EfficientNet-B0 yang terdapat pada Gambar 4.

Penelitian ini membagi dataset menjadi 75% yang digunakan untuk data latih dan 25% untuk data uji. Sehingga jumlah data latih yang digunakan adalah 1361 citra dan data uji yang digunakan 454 citra. Sistem model yang dibuat divalidasi dengan menggunakan data uji. Terdapat 5 skenario yang akan dilakukan dan mencari akurasi terbaik.

Skenario 1 dilakukan *resize* untuk mencari ukuran citra terbaik. Skenario 2 dilakukan untuk mencari *optimizer* terbaik. Skenario 3 dilakukan untuk mencari nilai *learning rate* terbaik. Skenario 4 dilakukan dengan mencari nilai *epoch* terbaik. Skenario 5 dilakukan dengan mencari nilai *batch size* terbaik.

3. HASIL DAN PEMBAHASAN

Pada penelitian digunakan 5 skenario pengujian dengan beberapa parameter yang berbeda untuk setiap skenario. Pengujian ini dilakukan untuk mengukur parameter performansi sistem serta akurasi sistem. Parameter terbaik dari setiap skenario diambil sehingga dapat melanjutkan ke skenario pengujian selanjutnya. Hal ini bertujuan untuk menentukan model terbaik dari sistem.

3.1 Skenario 1: *Pre-Processing Resize Citra*

Skenario pertama adalah melakukan *pre-processing resize* citra untuk mencari ukuran citra terbaik dalam meningkatkan akurasi sistem. Jenis *resize* yang digunakan pada skenario ini adalah 32×32 pixels, 64×64 pixels, 128×128 pixels, dan 224×224 pixels. Parameter yang lain ditentukan seperti *optimizer* Adam, *epoch* 50, *batch size* 32, dan *learning rate* 0,001. Hasil dari pengujian pengaruh *pre-processing resize* citra ditampilkan dalam Tabel 1.

Tabel 1. Hasil Pengujian Pre-Processing Resize Citra

Parameter	Hasil Pengujian <i>Resize</i>		
	(32×32) px	(64×64) px	(128×128) px
Akurasi	0,9714	0,9868	1,0000
Presisi	0,9740	0,9860	1,0000
<i>Recall</i>	0,9700	0,9860	1,0000
F1-Score	0,9700	0,9840	1,0000
<i>Loss</i>	0,1044	0,0539	0,0011
Waktu Komputasi	695 s	797 s	934 s

Dari Tabel 1 diketahui jika menggunakan *resize* citra dengan ukuran 128×128 pixels memperoleh hasil terbaik dibandingkan dengan ukuran citra lainnya, dengan nilai akurasi, presisi, *recall* dan F1-Score sebesar 1,0000 dengan waktu komputasi 934 detik. Perbedaan akurasi, presisi, *recall* dan F1-Score pada sistem tersebut disebabkan oleh semakin kecil ukuran citra dapat mengakibatkan informasi yang terkandung dalam citra banyak yang hilang. Selain itu, semakin besar ukuran *resize* citra maka waktu komputasinya semakin lama.

3.2 Skenario 2: Pengaruh *Optimizer*

Skenario kedua dilakukan untuk mengetahui pengaruh *optimizer* terhadap tingkat akurasi sistem. Parameter terbaik dari skenario sebelumnya, *resize* citra 128×128 *pixels* digunakan pada pengujian pengaruh *optimizer*. Namun, parameter lainnya telah ditentukan seperti, *batch size* 32, *epoch* 50, dan *learning rate* 0,001. Tabel 2 yang menunjukkan hasil dari pengujian skenario 2.

Tabel 2. Pengujian *Optimizer*

Parameter	Hasil Pengujian <i>Optimizer</i>				
	Adam	Adamax	Nadam	RMSprop	SGD
Akurasi	0,9890	0,9978	0,9846	0,9890	0,8348
Presisi	0,9880	0,9980	0,9860	0,9880	0,8420
<i>Recall</i>	0,9900	0,9980	0,9840	0,9900	0,8300
F1- <i>Score</i>	0,9880	0,9960	0,9860	0,9880	0,8280
<i>Loss</i>	0,0555	0,0086	0,0518	0,0240	0,8061

Berdasarkan Tabel 2 perbandingan pengujian pengaruh optimizer didapatkan akurasi tertinggi sebesar 0,9978 dengan menggunakan *optimizer* Adamax dengan nilai *loss* sebesar 0,0086, nilai presisi 0,9980, nilai *recall* 0,9980 dan nilai F1-*Score* 0,9960. Dengan menggunakan optimizer Adamax dapat disimpulkan bahwa model lebih optimal dalam mengklasifikasikan glaukoma dilihat dari performansi akurasi, presisi, *recall* dan F1-*Score*.

3.3 Skenario 3: Pengaruh *Learning Rate*

Skenario ke-3 menggunakan citra dengan parameter terbaik yang didapat dari skenario pengujian sebelumnya, yaitu *resize* citra 128×128 dan *optimizer* Adamax sedangkan parameter lain, yaitu *epoch* 50 dan *batch size* 32 telah ditentukan. Pengujian dengan learning rate dilakukan untuk mengukur tingkat akurasi sistem. Pada Tabel 3 ditunjukkan hasil pengujian *learning rate*.

Tabel 3. Hasil Pengujian *Learning Rate*

Parameter	Hasil Pengujian <i>Learning Rate</i>			
	0,1	0,01	0,001	0,0001
Akurasi	0,3458	0,9581	1,0000	0,9978
Presisi	0,3980	0,9640	1,0000	0,9980
<i>Recall</i>	0,3540	0,9600	1,0000	0,9980
F1- <i>Score</i>	0,2820	0,9580	1,0000	0,9960
<i>Loss</i>	3,2588	0,1354	$1,3682 \times 10^{-5}$	0,0155

Hasil akurasi tertinggi pada Tabel 3 ditunjukkan pada saat menggunakan *learning rate* 0,001 dengan nilai akurasi mencapai 1,0000 dengan nilai *loss* sistem $1,3682 \times 10^{-5}$, nilai presisi, *recall* dan F1-*Score* adalah 1,0000. Semakin kecil nilai *learning rate* maka akurasinya akan semakin

tinggi. Artinya, sistem akan semakin teliti dalam mengklasifikasikan citra sesuai dengan kelasnya.

3.4 Skenario 4: Pengaruh Nilai *Epoch*

Pada pengujian pengaruh *epoch* dilakukan empat kali percobaan dengan nilai *epoch*, 8, 10, 15, dan 20. *Epoch* digunakan untuk menentukan jumlah iterasi dalam pembaharuan bobot jaringan. *Epoch* dapat membantu dalam meminimalisir *error*. Parameter citra yang digunakan merupakan parameter citra dengan akurasi terbaik hasil dari skenario pengujian sebelumnya, yaitu *resize* citra 128×128 , *optimizer* Adamax, *learning rate* 0,001 dan *batch size* yang telah ditentukan, yaitu 32.

Tabel 4. Hasil Pengujian Nilai *Epoch*

Parameter	Hasil Pengujian <i>Epoch</i>			
	8	10	15	20
Akurasi	0,3348	0,6189	0,9934	1,0000
Presisi	0,5180	0,7560	0,9940	1,0000
<i>Recall</i>	0,3260	0,6160	0,9940	1,0000
F1- <i>Score</i>	0,2720	0,6280	0,9920	1,0000
<i>Loss</i>	2,8920	1,1354	0,0196	$1,2121 \times 10^{-4}$

Berdasarkan Tabel 4 diatas didapatkan akurasi tertinggi terdapat pada *epoch* 20 dengan akurasi mencapai 1,0000 dengan nilai *loss* sistem $1,2121 \times 10^{-4}$, nilai presisi, *recall* dan F1-*Score* masing-masing 1,0000.

3.5 Skenario 5: Pengaruh *Batch Size*

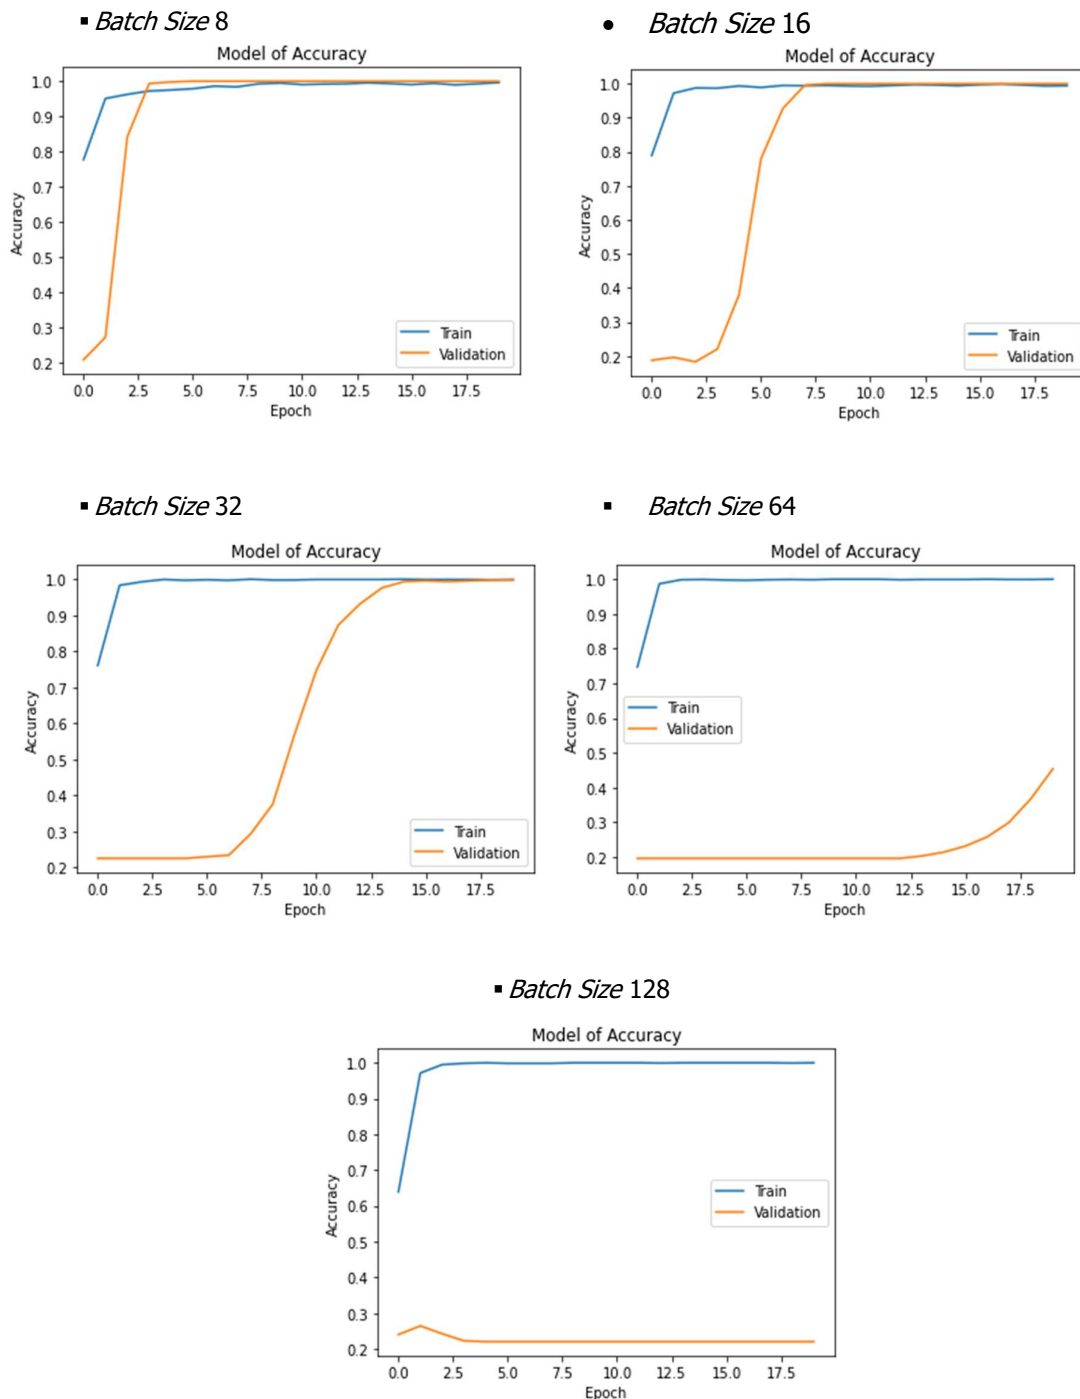
Pengujian pengaruh *batch size* merupakan pengujian skenario kelima. Parameter yang digunakan pada citra adalah parameter terbaik yang diperoleh dari skenario pengujian sebelumnya yang terdiri dari *resize* citra 128×128 *pixels*, *optimizer* adamax, *learning rate* 0,001, dan *epoch* 20. Ukuran *batch size* yang digunakan diantaranya adalah 8, 16, 32, 64, dan 128.

Tabel 5. Hasil Pengujian *Batch Size*

Parameter	Hasil Pengujian <i>Batch Size</i>				
	8	16	32	64	128
Akurasi	1,0000	1,0000	1,0000	0,5352	0,1740
Presisi	1,0000	1,0000	1,0000	0,7480	0,0840
<i>Recall</i>	1,0000	1,0000	1,0000	0,5280	0,1960
F1- <i>Score</i>	1,0000	1,0000	1,0000	0,5420	0,0620
<i>Loss</i>	$9,0601 \times 10^{-5}$	$6,7841 \times 10^{-4}$	$1,3718 \times 10^{-4}$	1,8909	4,1706

Berdasarkan Tabel 5 dapat diketahui bahwa akurasi tertinggi mencapai 1,0000 terdapat pada citra yang menggunakan parameter *batch size* 8, 16 dan 32. Dengan menghasilkan nilai *loss* sistem $9,0601 \times 10^{-5}$ saat menggunakan *batch size* 8, $6,7841 \times 10^{-4}$ saat menggunakan *batch*

size 16, dan $1,3718 \times 10^{-4}$ saat menggunakan *batch size* 32. Selain itu nilai presisi, *recall* dan F1-Score dari penggunaan ketiga *batch size* itu juga sama, yaitu 1,0000.



Gambar 5. Perbandingan Grafik Akurasi

Pada Gambar 5 perbandingan grafik akurasi diatas didapatkan jika sistem yang diteliti paling baik saat menggunakan *batch size* 32. Saat menggunakan *batch size* yang lebih kecil, sistem akan mencapai nilai optimal lebih cepat dibandingkan dengan menggunakan *batch size* yang lebih besar.

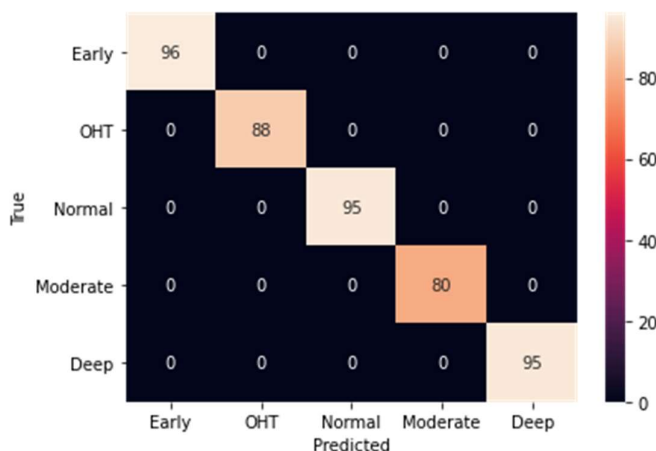
Tabel 6. Perbandingan Nilai Akurasi Uji dan Akurasi Validasi

	8	16	32	64	128
Akurasi <i>Train</i>	0,9904	0,9963	0,9985	0,9993	0,9985
Akurasi Validasi	1,0000	1,0000	1,0000	0,5352	0,1740
<i>GAP</i>	0,0096	0,0037	0,0015	0,4641	0,8245

Berdasarkan Tabel 6, yaitu Tabel perbandingan nilai akurasi uji dan akurasi validasi diperoleh gap untuk *batch size* 32 lebih kecil dibandingkan dengan yang lainnya. Artinya, kemungkinan untuk terjadi *overfitting*-nya rendah. Maka, *batch size* yang paling ideal digunakan untuk sistem ini adalah *batch size* 32. Dengan tetap mempertimbangkan nilai akurasi, performansi presisi, *recall*, dan *F1-Score*.

3.6 Confusion Matrix

Gambar 6 berikut ini adalah *confusion matrix* dari paramter terbaik.



Gambar 6. Confusion Matrix Sistem

Dari skenario 5 diperoleh akurasi sebesar 1,0000. Pada *confusion matrix* yang dimuat gambar 6 dapat diketahui jika sistem mampu mengklasifikasikan glaukoma tipe *early* sebanyak 96 citra, glaukoma tipe OHT sebanyak 88 citra, glaukoma tipe *moderate* 80 citra, glaukoma tipe *deep* 95 citra, dan normal 95 citra. Dapat disimpulkan jika sistem dapat menggolongkan glaukoma kedalam lima kelas secara benar. Hal ini dapat dibuktikan dengan tidak adanya kesalahan deteksi pada matriks.

4. KESIMPULAN

Penelitian ini telah merancang sistem untuk klasifikasi penyakit glaukoma ke dalam 5 kelas dengan menggunakan CNN dengan model EfficientNet-B0 dan memperoleh hasil akurasi sebesar 1,0000 dengan nilai presisi sebesar 1,0000, nilai *recall* sebesar 1,0000 dan *F1-Score* sebesar 1,0000 yang dicapai dengan menggunakan *optimizer* AdaMax, learning rate 0.001, dan *batch size* 32. Penggunaan arsitektur EfficientNet-B0 mempengaruhi hasil penelitian ini salah satunya disebabkan karena terdapat 234 *layer* yang digunakan. Selain itu, model EfficientNet secara umum mempunyai akurasi yang lebih tinggi dan efisiensi yang lebih baik

dibandingkan CNN lainnya, dengan mengurangi ukuran parameter dan FLOPS dengan urutan besarnya. Maka dari itu dapat disimpulkan bahwa sistem mampu mengklasifikasikan glaukoma dengan baik dan sesuai dengan kelasnya. Untuk penelitian kedepannya, disarankan menggunakan dataset untuk citra jenis lain ataupun menggunakan citra glaukoma yang lain, misalnya ORIGA, MESSIDOR, Drishti-GS. Selain itu, dapat juga menggunakan *deep learning* CNN dengan arsitektur yang lain untuk membuat sistem klasifikasi glaukoma ke dalam lima kelas. Misalnya, Alexnet, GoogLeNet, ResNeXt-50, dan Inception-v4.

DAFTAR RUJUKAN

- Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., & Alajlan, N. A. (2021). Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model with Attention. *IEEE Access*, *9*, 14078–14094.
- Fumero, F., Alayon, S., Sanchez, J., Sigut, J., & Gonzalez-Hernandez, M. (2011). RIM-ONE: An Open Retinal Image Database for Optic Nerve Evaluation. *Computer-Based Medical Systems (CBMS)*, 1-6.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, Nomor January).
- Hussain, Z., Gimenez, F., Yi, D., & Rubin, D. (2017). Differential Data Augmentation Techniques for Medical Imaging Classification Tasks. *AMIA ... Annual Symposium proceedings. AMIA Symposium, 2017*, (pp. 979–984).
- Kurian, Preethi, dan JeyakumarVijay. (2020). Multimodality Medical Image Retrieval Using Convolutional Neural Network. Academis Press: *Elsevier Science*.
- Kizrak, M. A., Muftuoglu, Z., Yildirim, T. (2020). Limitations and challenges on the diagnosis of COVID-19 using radiology images and deep learning. *Human Relations*, *3*(1), 1–8.
- Nugraha, G. S., Riyandari, B. A., & Sutoyo, E. (2020). RGB Channel Analysis for Glaucoma Detection in Retinal Fundus Image. *2020 International Conference on Advancement in Data Science, E-learning and Information Systems (ICADEIS)*, (pp. 1-5).
- Padaria, A., & Limbasiya, B. (2015). Detection of Glaucoma Using Retinal Fundus Images With Gabor Filter. *International Journal of Advance Engineering and Research Development*, *2*(6).
- Rayungsista, A. (2018). Characteristics Of Primary Glaucoma In Eye Outpatient Clinic Of RA Basoeni Hospital, Mojokerto, Indonesia. *Folia Medica Indonesiana*, 172-178.

- Saxena, M. A., Vyas, M. A., Parashar, M. L., & Vyas, M. A. (2020). A Glaucoma Detection using Convolutional Neural Network. *Proceedings of the International Conference on Electronics and Sustainable Communication Systems, ICESC 2020*, (pp. 815–820).
- Serener, A., & Serte, S. (2019). Transfer Learning for Early and Advanced Glaucoma Detection with Convolutional Neural Networks. *Medical Technologies Congress (TIPTEKNO)*, Turkey, 1–4.
- Suryansah, A., Habibi, R., & Awangga, R. M. (2020). *Penggunaan Face Recognition untuk Akses Ruangan*. Bandung: Redaksi.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *36th International Conference on Machine Learning, ICML 2019, 2019-June*, (pp. 10691–10700).
- Touahri, R., Azizi, N., Benzebouchi, N. E., Hammami, N. E., & Moumene, O. (2018). "A Comparative Study of Convolutional Neural Network and Twin SVM for Automatic Glaucoma Diagnosis." *2018 International Conference on Signal, Image, Vision and their Applications, SIVA 2018*, (pp. 1–5).
- Yu, M., Huang, Q., Qin, H., Scheele, C., & Yang, C. (2019). Deep Learning for Real-Time Social Media Text Classification for Situation Awareness - using Hurricanes Sandy, Harvey, and Irma as Case Studies. *International Journal of Digital Earth*, 1-18.