

## GLAUCOMA CLASSIFICATION BASED ON FUNDUS IMAGES PROCESSING WITH CONVOLUTIONAL NEURAL NETWORK

Yunendah Nur Fuadah<sup>\*1</sup>, Sofia Saidah<sup>2</sup>, Nidaan Khofiya Sy<sup>3</sup>, Rita Magdalena<sup>4</sup>, Ibnu Da'wan Ubaidullah<sup>5</sup>

<sup>1,2,3,4,5</sup>Fakultas Teknik Elektro, Universitas Telkom, Indonesia  
Email: [yunendah@telkomuniversity.ac.id](mailto:yunendah@telkomuniversity.ac.id)

(Naskah masuk: 16 April 2022, Revisi : 18 Mei 2022, diterbitkan: 28 Juni 2022)

### Abstract

*Glaucoma is an eye disease that causes damage to the optic nerve due to increased pressure in the eyeball. Delay in diagnosis and treatment of optic nerve damage due to glaucoma can lead to permanent blindness. Thus, several studies have developed a glaucoma early detection system based on digital image processing and machine learning. This study carried out glaucoma classification based on fundus image processing using Convolutional Neural Network (CNN). The CNN architecture proposed in this study consists of three convolutional layers with output channels 8, 16, 32 sequentially and a filter size of 5×5 at each layer, followed by a pooling layer and a dropout layer at the feature extraction stage. Furthermore, a fully connected layer and softmax activation function was implemented at the classification stage to classify fundus images into normal conditions, early glaucoma, moderate glaucoma, deep glaucoma, and ocular hypertension (OHT). The total amount of fundus image data used in this study consisted of 2000 fundus images divided into 1280 training data, 320 validation data, and 400 test data. 5-fold cross-validation is implemented in the training phase to select the best model. At the testing stage, the best accuracy generated by 99%, with the precision value, recall, f-1 scores and the AUC score are close to 1. According to the system performance results obtained, the proposed model can be used as a tool for medical personnel in classifying glaucoma conditions to provide appropriate medical treatment and reduce the risk of permanent blindness due to glaucoma.*

**Keywords:** *Glaucoma, Fundus Images, Image Processing, Machine learning, Convolutional Neural Network.*

## KLASIFIKASI GLAUKOMA BERDASARKAN PENGOLAHAN CITRA FUNDUS DENGAN CONVOLUTIONAL NEURAL NETWORK

### Abstrak

Glaukoma merupakan penyakit mata yang mengakibatkan kerusakan saraf optik diakibatkan oleh terjadinya peningkatan tekanan pada bola mata. Keterlambatan diagnosa dan penanganan kerusakan saraf optik akibat glaukoma dapat menyebabkan kebutaan secara permanen. Sehingga, beberapa penelitian mengembangkan sistem deteksi dini glaukoma berbasis pengolahan citra digital dan *machine learning*. Pada penelitian ini, klasifikasi glaukoma dilakukan berbasis pengolahan citra fundus menggunakan *Convolutional Neural Network* (CNN). Arsitektur CNN yang diusulkan pada penelitian ini terdiri dari tiga *convolutional layers* dengan jumlah *output channel* 8, 16, 32 secara berurutan, serta ukuran filter 5×5 pada setiap layer, diikuti *pooling layer* dan *dropout layer* pada tahap ekstraksi ciri. Selanjutnya, pada tahap klasifikasi diimplementasikan *fully connected layer* dan fungsi aktivasi *softmax* untuk mengklasifikasikan citra fundus ke dalam kondisi normal, *early glaukoma*, *moderate glaukoma*, *deep glaukoma* dan *ocular hypertension* (OHT). Jumlah keseluruhan data citra fundus yang digunakan pada penelitian ini terdiri dari 2000 citra fundus yang dibagi menjadi 1280 data latih, 320 data validasi, dan 400 data uji. Pada tahap pelatihan, *5-fold cross validation* diimplementasikan untuk seleksi model terbaik. Pada tahap pengujian, akurasi terbaik yang dihasilkan sebesar 99%, dengan nilai presisi, *recall*, *f-1 score* serta *AUC score* mendekati 1. Berdasarkan hasil performansi sistem yang diperoleh, model yang diusulkan dapat digunakan sebagai alat bantu tenaga medis dalam mengklasifikasikan kondisi glaukoma sehingga dapat memberikan penanganan medis yang tepat dan mengurangi resiko kebutaan permanen akibat glaukoma.

**Kata kunci:** *Glaukoma, Fundus Images, Image Processing, Machine learning, Convolutional Neural Network (CNN).*

## 1. PENDAHULUAN

Glaukoma merupakan salah satu penyakit mata, dimana terjadi kerusakan pada saraf optik yang terjadi akibat adanya peningkatan tekanan pada bola mata. Penyakit ini merupakan penyakit kedua terbanyak sebagai penyebab kebutaan di seluruh dunia setelah katarak. Menurut data WHO pada tahun 2010, sebanyak 3,2 juta orang mengalami kebutaan akibat penyakit glaukoma [1]. *Survey Kesehatan* tahun 1993-1996 menyebutkan bahwa 1,5% penduduk Negara Indonesia mengalami kebutaan. Sebanyak 0,2% kebutaan tersebut diakibatkan oleh penyakit glaukoma. Penyakit glaukoma merupakan salah satu penyakit yang gejala awalnya sulit dideteksi. Penyakit glaukoma ini perlahan dapat menyebabkan kebutaan permanen tanpa gejala awal [2]. Mayoritas penderita kebutaan akibat glaukoma tidak menyadari bahwa mereka menderita glaukoma dan baru terdiagnosis saat penyakit tersebut memasuki stadium lanjut. Selain itu, untuk mendeteksi ada atau tidaknya penyakit glaukoma pada seseorang, membutuhkan pemeriksaan yang cukup rumit karena penderita harus mendatangi rumah sakit khusus mata. Sementara itu, bagi para penduduk yang tinggal di daerah terpencil, cukup sulit untuk menjangkau fasilitas kesehatan yang memadai yang hanya bisa ditemui di kota-kota besar.

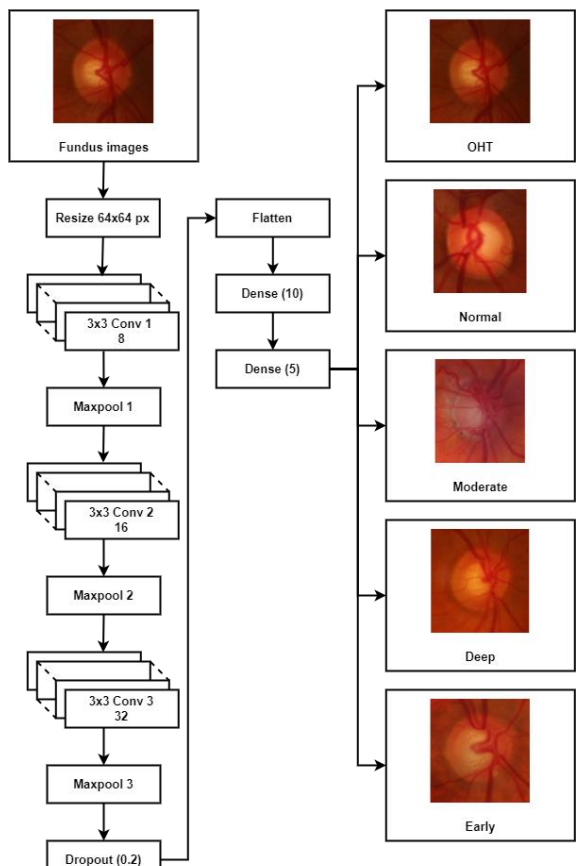
Bahaya glaukoma yang disadari oleh masyarakat dan sulitnya menjangkau fasilitas Kesehatan khusus penyakit mata untuk mendeteksi penyakit glaukoma membuat para peneliti berlomba untuk merancang sistem deteksi dini penyakit glaukoma. Beberapa penelitian yang telah dikembangkan terkait deteksi dini penyakit glaukoma. Pada penelitian [3] Khaing, Tin Tin dkk, melakukan penelitian mengenai deteksi penyakit glaukoma menggunakan berbasis aplikasi pada *smartphone* melalui citra retina. Penelitian tersebut menggunakan metode segmentasi *Alternated Deation-Ination Gradient Vector Flow* (ADI-GVF) yang diintegrasikan dengan *exclusion method* (EM) *initaliation* untuk meningkatkan akurasi. Pengambilan citra fundus retina dilakukan menggunakan kamera fundus yang terhubung langsung dan diproses menggunakan *smartphone*. Hasil penelitian menunjukkan bahwa sistem yang dirancang mampu mengklasifikasikan 42 data citra normal dan 42 data citra glaukoma dengan hasil sensitifitas sebesar 93,33% dan spesifisitas 93,87%. Pada penelitian lainnya [4] Devecioglu, O.C. dkk melakukan deteksi glaukoma secara real-time berbasis citra fundus digital menggunakan Self-ONNs. Pada penelitian tersebut, peneliti mengklaim bahwa Self-ONNs tidak hanya mampu memberikan performansi deteksi yang baik, tapi juga secara signifikan mampu mengurangi kompleksitas komputasi dalam membuat model untuk dataset biomedis. Hasil dari penelitian menunjukkan *gap f-1 score* sebesar 8-12% jika dibandingkan dengan metode *deep CNN*. Penelitian lainnya [5] yang

dilakukan oleh Madhusudhan, M. menunjukkan bahwa penyakit glaukoma juga mampu dideteksi dengan teknik pemrosesan citra. Pada penelitian ini digunakan metode segmentasi untuk *pre-processing* dan klasifikasi dilakukan dengan mengevaluasi nilai CDR (*Cup Disk Ratio*). Sistem yang dirancang menunjukkan performansi sistem berupa nilai sensitifitas sebesar 89,47% dan spesifisitas 83,33%. Sementara itu, pada penelitian [6] Sheba O dkk, melakukan deteksi glaukoma menggunakan metode *Artificial Neural Network* (ANN). Dataset yang digunakan adalah data primer yang diambil menggunakan kamera fundus yang kemudian diproses menggunakan Matlab. Tahap pengujian dilakukan terhadap 28 pasien glaukoma dan 12 pasien dengan mata normal. Dari 40 data yang diuji, sebanyak 34 data dapat terklasifikasikan dengan benar. Penelitian lainnya terkait deteksi glaukoma [7] dilakukan oleh Rabbia Mahum dkk dengan judul "A Novel Hybrid Approach Based on Deep CNN to Detect Glaukoma using Fundus Imaging". Dari 1500 dataset citra fundus, sebanyak 40% digunakan sebagai data uji. Sistem yang dirancang menghasilkan akurasi sebesar 99% pada citra uji dan 98,8% akurasi dengan menggunakan metode *cross validation*. Sementara itu, pada penelitian [8] Mafla Claro dkk melakukan deteksi otomatis terhadap penyakit glaukoma berbasis segmentasi *optic disk* dan ekstraksi ciri tekstur menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Dataset sebanyak 329 citra yang digunakan merupakan dataset sekunder yang diperoleh dari *RIM-ONE*, *DRISTHI-GS* dan *DRIONS-DB*. Performansi sistem tertinggi diperoleh ketika menggunakan metode klasifikasi *Multi Layer Perceptron* (MLP) dengan akurasi yang diperoleh sebesar 93,03%. Penelitian lainnya [9] melakukan deteksi Glaukoma dengan teknik pemrosesan citra menggunakan *Cup-to-Disc Ratio*. Dengan metode CDR, diperoleh hasil bahwa sebanyak 27 dari 29 data citra normal dan 12 dari 15 citra glaukoma dapat terklasifikasikan dengan benar. Total akurasi yang diperoleh adalah 89%. Penelitian [10] juga melakukan deteksi Glaukoma berbasis citra fundus. Pada penelitian ini, metode *Principal Component Analysis* (PCA) digunakan sebagai metode ekstraksi ciri, sementara untuk klasifikasi digunakan metode *Least Square Support Vector Machine* (LS-SVM). Dari 150 citra glaukoma dan 100 citra normal yang digunakan, diperoleh hasil akurasi terbaik sebesar 99%. Penelitian lainnya [11] melakukan deteksi glaukoma pada citra fundus dengan metode segmentasi sebagai metode ekstraksi ciri dan metode SVM untuk klasifikasi. Hasil yang diperoleh dengan kombinasi kedua metode tersebut terbilang sangat baik, yaitu akurasi 94,11% dan sensitifitas 100%. Dari penelitian terkait yang telah disebutkan diatas, sistem yang telah dirancang memerlukan tahapan ekstraksi ciri secara manual dan hanya dapat mengklasifikasikan data dengan jumlah yang terbatas untuk dua kondisi saja, yaitu

kondisi normal dan kondisi glaukoma. Oleh karena itu, penelitian ini menggunakan *Convolutional Neural Network* yang dapat secara otomatis mengekstraksi informasi pada citra fundus dan mengklasifikasikan 2000 citra fundus ke dalam lima kondisi yaitu *normal*, *early*, *moderate*, *deep* dan *OHT*.

**2. METODE PENELITIAN**

Penelitian ini mengembangkan sistem untuk klasifikasi penyakit glaukoma berdasarkan pengolahan citra digital pada citra fundus yang terbagi menjadi lima kondisi, antara lain, *early glaucoma*, *deep glaucoma*, *moderate glaucoma* dan *ocular hypertension* (OHT). Model CNN yang diusulkan pada penelitian ini terdiri dari tiga *convolutional layers* dengan jumlah *output channel* pada setiap layer-nya 16, 32, 64 secara berurutan dan ukuran filter 5x5 pada setiap layer, diikuti *pooling layer* dengan ukuran 5x5. Selanjutnya, pada tahap klasifikasi, *fully connectd layer* dan aktivasi softmax diimplementasikan untuk mengklasifikasikan penyakit glaukoma. Gambar 1 menunjukkan gambaran umum model CNN yang diusulkan pada penelitian ini.



Gambar 1. Arsitektur model CNN yang diusulkan

**2.1. Dataset**

Penelitian ini menggunakan Rim-One dataset yang terdiri dari 169 citra fundus yang terbagi


menjadi lima kelas yaitu *normal*, *early*, *moderate*, *deep* dan *OHT*. Selanjutnya, untuk memperbanyak jumlah citra dilakukan proses augmentasi citra fundus menjadi 2000 citra fundus dimana masing-masing kelas terdiri 400 citra.

**2.2. Convolutional Neural Network**

*Convolutional Neural Network* (CNN) merupakan pengembangan dari jaringan saraf tiruan *Multilayer Perceptron* (MLP) dan merupakan *Deep Neural Network* untuk pengolahan data dua dimensi berupa citra. CNN dapat mengenali suatu objek karena memiliki dua bagian utama pada metode pembelajarannya, yaitu mengekstraksi ciri khas dari suatu citra (*feature extraction*) dan melakukan klasifikasi berdasarkan ciri pada citra tersebut (*classification*) [12][13].


**2.2.1. Ekstraksi ciri**

Ekstraksi ciri adalah proses pengambilan informasi penting atau karakteristik dari suatu data citra yang akan diolah. Keluaran dari tahap ekstraksi ciri ini disebut *feature map* yang selanjutnya akan diproses pada tahap klasifikasi [14]. Secara umum tahap ekstraksi ciri ini terdiri dari *convolutional layer* dan *pooling layer*. Pada *convolutional layer* akan dilakukan proses konvolusi antara citra dengan suatu filter berupa matriks dengan ukuran tertentu untuk menghasilkan *feature map* [15]. Gambar 2 menunjukkan ilustrasi proses operasi konvolusi.



Gambar 2. Ilustrasi proses konvolusi [15]

Sedangkan pada *pooling layer* akan dilakukan proses *down-sampling* yang bertujuan untuk mengurangi ukuran *feature map* yang telah dihasilkan dari layer konvolusi. Metode *pooling* yang umumnya digunakan adalah *mean pooling* dan *max pooling*. *Mean pooling* akan mengambil nilai rata-rata dari setiap *grid* untuk menyusun matriks baru sedangkan *max pooling* akan mengambil nilai maksimal [15]. Gambar 3 menunjukkan ilustrasi proses pada *pooling layer*.



Gambar 3. Ilustrasi proses pooling [15]

### 2.2.2. Classification Layer

Pada *classification layer*, *feature map* yang berbentuk *multidimensional array* akan dijadikan vektor yang disebut dengan proses *flatten*. Selanjutnya, vektor tersebut akan menjadi masukan *fully connected layer* dimana semua *neuron* pada lapisan sebelumnya terhubung dengan lapisan setelahnya. Pada umumnya, dalam kasus klasifikasi *multiclass* (lebih dari dua kelas) digunakan fungsi aktivasi softmax pada tahap klasifikasi. Oleh karena itu, penelitian ini menggunakan fungsi aktivasi softmax dalam mengklasifikasikan citra fundus ke dalam 5 kelas yaitu normal, *early*, *moderate*, *deep*, dan OHT.

### 2.3. System Performance

Dalam mengevaluasi performansi sistem klasifikasi yang telah dirancang, dilakukan pengukuran parameter evaluasi kinerja sistem yang terdiri dari akurasi, presisi, *recall*, dan *f1-score*. Parameter-parameter tersebut diekspresikan dalam persamaan matematis sebagai berikut (1), (2), (3), dan (4) [16] [17].

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

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

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

$$F_1 - \text{Score} = 2 \times \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \quad (4)$$

Pada Persamaan (1), (2), dan (3), *True Positive* (TP) adalah hasil dimana model memprediksi kelas positif dengan benar sesuai dengan kelasnya. Sebaliknya, *True Negative* (TN), adalah hasil di mana model memprediksi kelas negatif dengan benar. *False Positive* (FP) adalah hasil di mana kelas negatif tetapi salah diklasifikasikan sebagai kelas positif. Sedangkan *False Negative* (FN) adalah hasil dimana kelas positif tetapi salah diklasifikasikan sebagai kelas negatif [16].

## 3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data dari Rim-One dataset yang diaugmentasi menjadi 2000 citra fundus yang terdiri dari 400 kelas normal, 400 kelas *early*, 400 kelas *moderate*, 400 kelas *deep*, dan 400 kelas OHT. Selanjutnya, data dibagi menjadi 1280 data latih, 320 data validasi, dan 400 data uji. Pada tahap pelatihan, dilakukan *5-fold cross validation* untuk pemilihan model terbaik yang akan digunakan pada tahap pengujian.


Performansi sistem diukur berdasarkan nilai akurasi, *recall*, presisi, dan *f1 score*. Beberapa metode optimasi yang terdiri dari Adam, Nadam,

SGD, dan RMSprop serta penggunaan learning rate sebesar 0.01, 0,001, dan 0,0001 digunakan untuk pemilihan parameter terbaik pada model 1-D CNN yang diusulkan. Tabel 1 menunjukkan performansi model 1D-CNN yang digunakan pada dalam penelitian ini.

Tabel 1. Performansi system yang diusulkan berdasarkan optimizer dan learning rate yang digunakan

Optimizer	Learning Rate	Accuracy		
		Train	Val	Test
Adam	0.0001	0.77	0.97	0.82
	<b>0.001</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>
	0.01	0.20	0.18	0.18
Nadam	0.0001	0.95	0.93	0.98
	0.001	0.97	0.99	0.96
	0.01	0.19	0.18	0.18
SGD	0.0001	0.23	0.18	0.25
	0.001	0.40	0.42	0.44
	0.01	0.96	0.95	0.97
RMSprop	0.0001	0.88	0.82	0.92
	0.001	0.99	0.98	0.99
	0.01	0.95	0.20	0.18


Berdasarkan hasil performansi sistem pada Tabel 1, *optimizer* Adam dengan learning rate 0.001 memberikan performansi terbaik dengan menghasilkan nilai akurasi 0.99 untuk data latih, validasi dan uji. Pemilihan *optimizer* dan *learning rate* sangat berpengaruh terhadap performansi sistem. *Optimizer* digunakan untuk mengoptimalkan performansi sistem dengan meminimalisir nilai *error*, sedangkan *learning rate* merupakan salah satu parameter pada tahap pelatihan untuk mengkalkulasi nilai koreksi bobot. Semakin kecil nilai *learning rate*, maka akan memerlukan proses pelatihan yang lama Sedangkan nilai *learning rate* yang semakin besar akan mempercepat proses pelatihan, akan tetapi mengurangi tingkat ketelitian. Dalam menentukan nilai *learning rate* yang optimal dilakukan melalui serangkaian pengujian.



Gambar 4. Confusion matrix data uji

Gambar 4 menunjukkan *confusion matrix* pengujian 400 data uji. Berdasarkan hasil yang diperoleh, secara umum model yang digunakan mampu mengklasifikasikan data uji kedalam 5 kelas (normal, *early*, *moderate*, *deep*, dan OHT). Dari 400 data uji, 398 data berhasil diklasifikasikan sesuai

dengan kelasnya, hanya terdapat 2 data yang salah diklasifikasikan.



Gambar 5. Kurva ROC data uji

Kurva ROC data uji pada Gambar 5 menunjukkan nilai *area under the curve* (AUC) yang dapat dijadikan parameter untuk mengetahui kemampuan sistem dalam melakukan klasifikasi antar kelas. Nilai AUC yang semakin besar menunjukkan model dapat mengklasifikasikan data dengan akurat. Berdasarkan hasil AUC yang diperoleh untuk masing-masing kelas, yaitu sebesar 0.99 menunjukkan kemampuan generalisasi data yang baik dari model yang diusulkan.

Tabel 2. Kinerja model yang diusulkan

Kelas	Presisi	Recall	F1-Score
Deep	1.00	1.00	1.00
Early	0.97	1.00	0.99
Moderate	1.00	1.00	1.00
Normal	1.00	0.98	0.99
OHT	1.00	1.00	1.00

Hasil evaluasi kinerja sistem berdasarkan perhitungan parameter presisi, *recall* dan *f1-score* ditunjukkan pada Tabel 2. Berdasarkan hasil pengujian data uji pada Tabel 2, menunjukkan nilai presisi, *recall*, dan *f1-score* yang maksimal untuk semua kelas. Hasil tersebut menunjukkan sistem yang diusulkan mampu mengklasifikasikan lima kondisi citra fundus secara akurat dengan *error* yang minimal.

#### 4. DISKUSI

Pada penelitian ini dilakukan pengujian untuk mengetahui pengaruh *optimizer* dan nilai *learning rate* yang digunakan terhadap performansi model CNN yang diusulkan. Berdasarkan hasil pengujian yang telah dilakukan, *optimizer* Adam memberikan performansi terbaik dengan memberikan nilai akurasi untuk data uji sebesar 99% dengan menggunakan nilai *learning rate* sebesar 0.001, diikuti oleh *optimizer* Nadam dengan performansi akurasi data uji sebesar 98% pada *learning rate* 0.0001, selanjutnya untuk *optimizer* RMS prop memberikan akurasi data uji sebesar 99% sama halnya seperti *optimizer* Adam, akan tetapi untuk akurasi data latih dan data validasi menggunakan *optimizer* RMSprop terlihat sedikit *overfitting* dimana akurasi data latih 1% lebih besar dari data

validasi sedangkan untuk *optimizer* Adam terlihat tidak *overfitting* dimana hasil akurasi data latih, data validasi, dan data uji memberikan nilai akurasi sebesar 99%. Berbeda dengan *optimizer* lainnya, *optimizer* SGD memberikan performansi akurasi yang sangat rendah ketika nilai *learning rate* kecil dan memberikan nilai akurasi data uji sebesar 97% ketika nilai *learning rate* sebesar 0.01.

Selanjutnya berdasarkan hasil pengujian dapat dilihat pengaruh *learning rate* terhadap performansi sistem. Penentuan nilai *learning rate* akan berpengaruh terhadap waktu komputasi model pada tahap training dan tingkat ketelitian dari model. Pemilihan nilai *learning rate* yang terlalu besar memang mempercepat waktu komputasi, akan tetapi tingkat ketelitian model berkurang, sehingga kita perlu melakukan sejumlah pengujian untuk memberikan performansi sistem yang paling optimal. Pada penelitian ini, nilai *learning rate* yang paling optimal adalah 0.001. Hal ini ditunjukkan dengan performansi akurasi yang tinggi dengan waktu komputasi yang lebih cepat dibandingkan nilai *learning rate* 0.0001.

Performansi model CNN yang diusulkan pada penelitian ini dapat disimpulkan melebihi performansi penelitian terkait sebelumnya untuk deteksi dan klasifikasi glaukoma yang menggunakan *dataset* yang sama yaitu *RIM-ONE dataset* dengan performansi akurasi sebesar 93.03% [8]. Selain itu, pada penelitian sebelumnya memerlukan beberapa tahapan proses *preprocessing*, ekstraksi ciri GLCM dan metode klasifikasi MLP. Sedangkan pada penelitian ini, model CNN yang diusulkan dapat secara langsung memproses *raw data* dari citra fundus sehingga dapat mengekstraksi informasi yang lebih detail dari citra fundus tersebut dibandingkan menggunakan metode ekstraksi ciri lain seperti GLCM yang hanya memberikan informasi statistik dari citra fundus. Oleh karena itu, performansi model CNN yang diusulkan penelitian ini memberikan performansi akurasi yang lebih tinggi dibandingkan metode sebelumnya.

#### 5. KESIMPULAN

Penelitian ini berhasil merancang sebuah sistem untuk mengklasifikasikan 5 kondisi penyakit glaukoma, yaitu *early glaucoma*, *deep glaucoma*, *moderate glaucoma* dan *ocular hypertension* (OHT) dengan akurasi mencapai 99% dan berhasil mengklasifikasikan 398 dari 400 data uji sesuai kelasnya. Arsitektur yang diusulkan untuk mencapai hasil maksimal adalah *Convolutional Neural Network* yang terdiri dari tiga *layer convolution* dengan filter pada masing-masing *layer* berukuran 5x5 kemudian diikuti *pooling layer* dan *dropout layer* pada tahap ekstraksi ciri, dan pada *layer* terakhir diimplementasikan *fully connected layer* dan fungsi aktivasi softmax untuk mengklasifikasikan masing-masing kelas. *Optimizer* dengan hasil terbaik adalah Adam *optimizer* dengan

learning rate 0.001. Sehingga sistem yang telah dirancang dapat diimplementasikan dalam dunia medis untuk membantu pendeteksian glaukoma sejak dini dan mengurangi resiko kebutaan permanen yang diakibatkan oleh glaukoma.

#### DAFTAR PUSTAKA

- [1] Kemenkes RI, "Infodatin Pusat Data dan Informasi Kementerian Kesehatan RI," *Millennium Challenge Account - Indonesia*. pp. 1–2, 2014. [Online]. Available: <https://pusdatin.kemkes.go.id/download.php?file=download/pusdatin/infodatin/infodatin-asi.pdf>
- [2] N. V. Balkrishna, N. C. Patil, K. Y. Ramesh, D. A. Sheshrao, G. Polytechnic, and G. Polytechnic, "A Review on Detection of Glaucoma from Retinal Fundus Images Using Digital Image Processing," *Int. J. Sci. Dev. Res.*, vol. 4, no. 12, pp. 154–157, 2019.
- [3] T. T. Khaing, T. Ruennark, P. Aimmanee, S. Makhanov, and N. Kanchanaranya, "Glaucoma Detection in Mobile Phone Retinal Images Based on ADI-GVF Segmentation with EM initialization," *ECTI Trans. Comput. Inf. Technol.*, vol. 15, no. 1 SE-Research Article, pp. 134–149, Jan. 2021, doi: 10.37936/ecti-cit.2021151.227261.
- [4] O. C. Devecioglu, J. Malik, T. Ince, S. Kiranyaz, E. Atalay, and M. Gabbouj, "Real-Time Glaucoma Detection from Digital Fundus Images Using Self-ONNs," *IEEE Access*, vol. 9, pp. 140031–140041, 2021, doi: 10.1109/ACCESS.2021.3118102.
- [5] M. Madhusudhan, N. Malay, S. R. Nirmala, and D. Samerendra, "Image processing techniques for glaucoma detection," *Commun. Comput. Inf. Sci.*, vol. 192 CCIS, no. PART 3, pp. 365–373, 2011, doi: 10.1007/978-3-642-22720-2\_38.
- [6] N. Sheeba, O., George, J., Rajin, P. K., Thomas, "Glaukoma detection using artificial neural network," *Int. Work. Comput. Sci. Eng.*, vol. 6, pp. 158–161, 2013, doi: <https://doi.org/10.7763/IJET.2014.V6.687>.
- [7] R. Mahum, S. U. Rehman, O. D. Okon, A. Alabrah, T. Meraj, and H. T. Rauf, "A Novel Hybrid Approach Based on Deep CNN to Detect Glaucoma Using Fundus Imaging," *Electronics*, vol. 11, no. 1, 2022, doi: 10.3390/electronics11010026.
- [8] M. Claro, L. Santos, W. Silva, F. H. Araújo, N. Moura, and A. Santana, "Automatic Glaucoma Detection Based on Optic Disc Segmentation and Texture Feature Extraction," *CLEI Electron. J.*, vol. 19, pp. 4:1-4:10, Aug. 2016, doi: 10.19153/cleiej.19.2.4.
- [9] C. Burana-Anusorn, W. Kongprawechnon, T. Kondo, and S. Sintuwong, "Image Processing Techniques for Glaucoma Detection Using the Cup-to-Disc Ratio Chalinee Burana-Anusorn," *Thammasat Int. J. Sci. Technol.*, vol. 18, no. 1, pp. 22–34, 2020.
- [10] L. Divya and J. Jacob, "Performance analysis of glaucoma detection approaches from fundus images," *Procedia Comput. Sci.*, vol. 143, pp. 544–551, 2018, doi: 10.1016/j.procs.2018.10.429.
- [11] D. Vijayasekar, S. Dhivya, S. Dhanalakshmi, and Dr. S. Karthik, "Survey on Detection of Glaucoma in Fundus Image by Segmentation and Classification," *Int. J. Eng. Res.*, vol. V4, no. 09, pp. 529–532, 2015, doi: 10.17577/ijertv4is090657.
- [12] Y. N. Fu'adah, N. C. Pratiwi, M. A. Pramudito, and N. Ibrahim, "Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 982, no. 1, 2020, doi: 10.1088/1757-899X/982/1/012005.
- [13] P. Gokila Brindha, M. Kaviraj, P. Manivasakam, and P. Prasanth, "Brain tumor detection from MRI images using deep learning techniques," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1055, no. 1, p. 012115, 2021, doi: 10.1088/1757-899x/1055/1/012115.
- [14] P. P. Ippolito, "Feature Extraction Techniques, Towards Data Science," 2019. <https://towardsdatascience.com/feature-extraction-techniques-d619b56e31be#:~:text=Feature Extraction aims to reduce,the original set of features>
- [15] I. B. L. M. Suta, R. S. Hartati, and Y. Divayana, "Diagnosa Tumor Otak Berdasarkan Citra MRI (Magnetic Resonance Imaging).pdf," *Maj. Ilm. Teknol. Elektro*, vol. 18, pp. 149–153, 2019.
- [16] J. D. Novakovic, A. Veljovic, S. S. Ilic, Z. Papic, and M. Tomovic, "Evaluation of Classification Models in Machine Learning.pdf," *Theory Appl. Math. Comput. Sci.*, pp. 39–46, 2017.
- [17] Putra, A. T., Usman, K., & Saidah, S. (2021). Webinar Student Presence System Based on Regional Convolutional Neural Network Using Face Recognition. *Jurnal Teknik Informatika (Jutif)*, 2(2), 109–118. <https://doi.org/10.20884/1.jutif.2021.2.2.82>