

# IDENTIFIKASI PENYAKIT MATA DENGAN KLASIFIKASI CITRA FOTO FUNDUS MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)

Muhammad Sirojul Qulub, Soffiana Agustin

Teknik Informatika, Universitas Muhammadiyah Gresik

Jl. Sumatera No.101, Gn. Malang, Randuagung, Kec. Kebomas, Kabupaten Gresik, Jawa Timur 61121

sirojulqulub27@gmail.com

## ABSTRAK

Penelitian ini berfokus pada deteksi dini penyakit mata menggunakan teknologi *Computer Vision* dan *Deep Learning*. Penyakit mata seperti *diabetic retinopathy*, glaukoma, katarak, degenerasi makula terkait usia, hipertensi okuli, dan miopia adalah penyebab utama kebutaan. Metode yang digunakan adalah *Convolutional Neural Networks* (CNN) dengan arsitektur VGG-16 untuk mengklasifikasikan citra foto fundus. Penelitian dilakukan dengan melatih dan menguji model klasifikasi menggunakan dataset citra foto fundus yang mencakup berbagai penyakit mata. Evaluasi dilakukan dengan mengukur akurasi, presisi, dan *recall* menggunakan *confusion matrix*. Hasil penelitian menunjukkan bahwa kinerja model dengan iterasi sebanyak 30 iterasi pada dataset yang menghasilkan *accuracy* sebesar 0,45 menunjukkan bahwa model dengan benar memprediksi label kelas sekitar 45% dari sampel.

**Kata kunci :** Deteksi penyakit mata, *Convolutional Neural Networks*, VGG-16, citra foto fundus.

## 1. PENDAHULUAN

Mata merupakan salah satu organ tubuh manusia yang paling penting. Selain sebagai organ tubuh, mata juga berperan sebagai alat indra penglihatan. Sebagai salah satu bagian dari organ tubuh tentunya mata tidak lepas dari serangan penyakit, entah itu serangan dari dalam maupun dari luar mata. Adapun yang paling sering menyerang mata adalah iritasi akibat masuknya benda-benda kecil seperti debu ataupun serangga dengan ukuran sangat kecil masuk ke dalam mata. Selain iritasi, ada juga penyakit lain yang apabila dibiarkan dapat menyebabkan kebutaan. Beberapa penyakit mata seperti *diabetic retinopathy*, *glaukoma*, *katarak*, degenerasi makula terkait usia, *hipertensi okuli* maupun *miopia* merupakan salah satu penyebab utama kebutaan pada manusia. Menurut Organisasi Kesehatan Dunia (WHO) saat ini, setidaknya 2,2 miliar orang di seluruh dunia mengalami gangguan penglihatan, di antaranya setidaknya 1 miliar memiliki gangguan penglihatan yang sebenarnya dapat dicegah [1]. Di Indonesia sendiri terdapat sejumlah 2.338 dokter spesialis mata yang terdaftar di Perhimpunan Dokter Spesialis Mata Indonesia (PERDAMI) yang tersebar di Indonesia. Jumlah ini dibandingkan jumlah penduduk Indonesia memiliki rasio sebesar 1:155.618. Rasio dokter spesialis mata telah mencapai target, namun distribusinya belum merata untuk seluruh Indonesia. Terdapat 19 provinsi yang rasionya belum mencapai 1:250.000 [2]. Karena banyaknya pasien dan kurangnya sumber daya medis di beberapa daerah, banyak pasien tidak dapat didiagnosis dan diobati tepat waktu, hingga akhirnya menyebabkan kehilangan ketajaman penglihatan yang bahkan kebutaan.

Deteksi dini penyakit mata merupakan cara yang ekonomis dan efektif untuk mencegah kebutaan yang disebabkan oleh *diabetic retinopathy*, *glaukoma*, *katarak*, degenerasi makula terkait usia (*Age-Related*

*Macular Degeneration*), *hipertensi okuli* maupun *miopia*. Pendeteksian penyakit pada retina dilakukan dengan pemeriksaan mata secara menyeluruh. *Computer Vision* dan *Deep Learning* dapat secara otomatis mendeteksi penyakit mata dengan membangun model klasifikasi menggunakan *Convolutional Neural Networks*. *Convolutional Neural Networks* atau CNN merupakan salah satu *Deep Learning* untuk *supervised learning* sehingga metode ini dapat mempelajari sendiri dan mencari sendiri fitur atau ciri yang dapat membantu mengidentifikasi citra. Hal ini membuat CNN banyak dikembangkan. Pada penelitian sebelumnya (Setiawan, 2019) yang membandingkan beberapa arsitektur CNN untuk klasifikasi *fundus* didapatkan bahwa menggunakan arsitektur VGG-16 memberikan Akurasi yang dicapai hingga 92,31% dengan Sensitivitas 90,7% dan spesififikasi 94%. Penelitian lainnya juga dilakukan oleh [3]. Pada penelitian tersebut klasifikasi dilakukan pada mata normal, *katarak*, *glaukoma* dan *retina disease*. Adapun data set yang digunakan berasal dari Jr2ngb dengan jumlah 610 yang terbagi ke 4 kelas normal, *katarak*, *glaukoma* dan *retina disease*. Adapun arsitektur yang digunakan pada penelitian ini adalah Alexnet. Pelatihan dilakukan dengan parameter epoch 150 mendapatkan hasil akurasi 98,37%. Selain itu ada juga penelitian yang dilakukan oleh [4]. Pada penelitian tersebut difokuskan untuk klasifikasi penyakit mata *retinopati diabetik* saja dengan menggunakan data set dari MESSIDOR yang berjumlah 900 data. Adapun arsitektur yang digunakan adalah rancangan dari penelitian tersebut dimana berisi tiga set kombinasi konvolusi yang masing – masing set akan berisikan lapisan konvolusi, ReLU, dan lapisan *pooling*. Hasil penelitian yang didapatkan kurang sesuai untuk mendeteksi *Retinopati Diabetik* karena memiliki rata – rata akurasi hasil pengujian sebesar 57,6%.

Dari permasalahan pendeteksian dini penyakit mata diusungkan dengan beberapa kelas, yaitu *Diabetic Retinopathy*, *Glaukoma*, *Karatak*, *Age-Related Macular Degeneration*, dan Normal. Kemudian berdasarkan penelitian yang terdahulu, metode yang dapat diimplementasikan untuk menyelesaikan permasalahan pendeteksian penyakit mata melalui citra *fundus* adalah menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16.

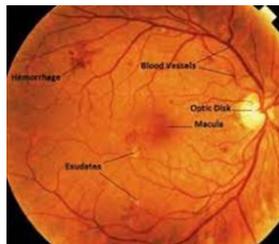
**2. TINJAUAN PUSTAKA.**

**2.1. Citra Foto Fundus**

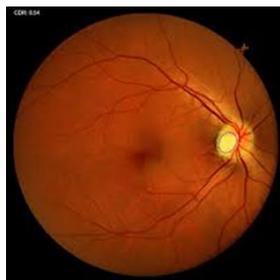
Citra foto *fundus* digital adalah foto retina yang berupa citra digital dengan pembesaran tinggi yang bertujuan untuk menampilkan detail – detail retina dan mendokumentasikan kondisi retina [5]. Foto *fundus* digital diambil dengan menggunakan kamera *fundus* atau kamera retina. Kamera *fundus* merupakan sebuah mikroskop berdaya rendah yang disertai kamera dengan desain untuk mengambil gambar permukaan bagian dalam mata termasuk retina, lensa mata, syaraf optik, makula, dan sebagainya. Kamera *fundus* digunakan para ahli untuk memonitor perkembangan suatu penyakit, diagnosa penyakit, atau dalam program *screening* dimana foto tersebut dianalisis [5].



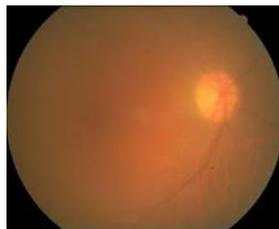
(a) Fundus mata normal



(b) Fundus diabetic retinopathy



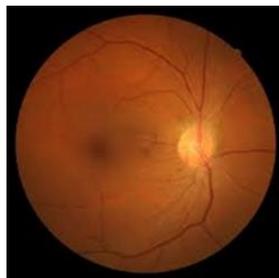
(c) Fundus glaukoma



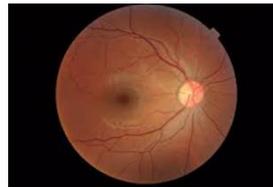
(d) Fundus katarak



(e) Fundus age-related macular degeneration



(f) Fundus hipertensi okuli



(d) Fundus miopia

Gambar 1. Fundus penyakit mata

**2.2. Augmentation**

*Augmentation* data merupakan suatu teknik untuk menyelesaikan permasalahan keterbatasan data yang dimiliki pada saat penelitian [6]. Selain itu *Augmentation* data juga mencegah terjadinya *overfitting*, yaitu variasi data yang digunakan terlalu kompleks sehingga menyebabkan tingginya akurasi pada proses pelatihan namun pada proses pengujian nilai akurasi rendah [7]. Dari berbagai macam metode *Augmentation* yang banyak digunakan adalah rotasi dan refleksi.

**2.3. Rotasi**

Rotasi adalah proses perpindahan nilai *pixel* suatu citra sebesar  $\theta^\circ$  yang dihitung dari pusat rotasi menggunakan Persamaan berikut :

$$\begin{bmatrix} x_2 \\ y_2 \end{bmatrix} = \begin{bmatrix} \cos \theta^\circ & -\sin \theta^\circ \\ \sin \theta^\circ & \cos \theta^\circ \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \end{bmatrix}$$

Keterangan:

$x_1$ : Titik koordinat pixel awal sebelum rotasi vertikal

$y_1$ : Titik koordinat pixel awal sebelum rotasi horizontal

$x_2$ : Titik koordinat pixel awal setelah rotasi vertikal

$y_2$ : Titik koordinat pixel awal setelah rotasi horizontal

Di mana suatu pixel gambar pada titik koordinat  $(x_1, y_1)$  diputar sebesar  $\theta^\circ$  dengan pusat  $(0, 0)$  menghasilkan *pixel* gambar dengan titik koordinat  $(x_2, y_2)$ .

**2.4. Refleksi**

Refleksi adalah proses perubahan posisi nilai pixel suatu citra berdasarkan sumbu x dihitung menggunakan Persamaan berikut :

$$\begin{bmatrix} x_2 \\ y_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \end{bmatrix}$$

Keterangan:

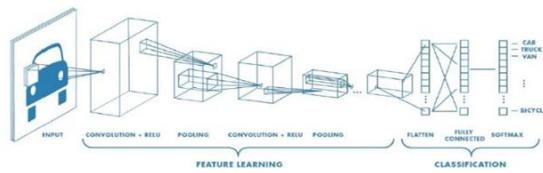
$x_1$ : Titik koordinat pixel awal sebelum refleksi vertikal  
 $y_1$ : Titik koordinat pixel awal sebelum refleksi horizontal

$x_2$ : Titik koordinat pixel awal setelah refleksi vertikal  
 $y_2$ : Titik koordinat pixel awal setelah refleksi horizontal

Di mana suatu pixel gambar pada titik koordinat  $(x_1, y_1)$  direfeksi terhadap sumbu x menghasilkan pixel gambar dengan titik koordinat  $(x_2, y_2)$ .

**2.5. Convolutional Neural Network (CNN)**

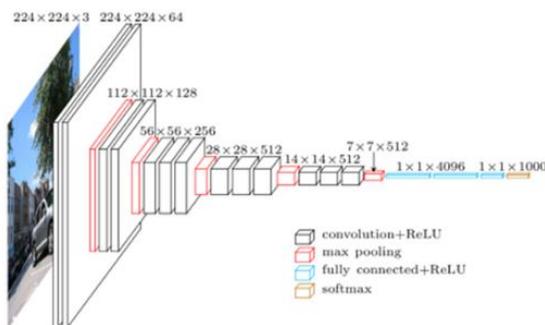
Convolutional Neural Network (CNN), juga disebut ConvNet, adalah jenis Artificial Neural Network (ANN), yang memiliki arsitektur *feed-forward* yang dalam dan memiliki kemampuan generalisasi yang luar biasa dibandingkan dengan Neural Network lain. Model CNN yang dalam terdiri dari serangkaian lapisan pemrosesan terbatas yang dapat mempelajari berbagai fitur data input (misalnya gambar). CNN dapat mempelajari fitur yang sangat abstrak dari objek khususnya data spasial dan dapat mengidentifikasinya secara lebih efisien [8]. Gambar 2 adalah jaringan arsitektur Convolutional Neural Network :



Gambar 2. Arsitektur CNN

**2.6. VGG-16**

VGG adalah salah satu arsitektur CNN paling populer, yang diperkenalkan pada tahun 2014. VGG memperkenalkan total 6 konfigurasi CNN yang berbeda, di antaranya VGG-16 dan VGG-19 adalah yang paling sukses [8]. VGG-16 merupakan varian dari model VGG yang terdiri dari 16 layer. VGG-16 adalah convolutional neural network yang dilatih menggunakan gambar dari database ImageNet yang terdiri kumpulan data lebih dari 14 juta gambar yang termasuk dalam 1000 kelas. Model ini mencapai akurasi pengujian 92,7% dan menjadi top 5 di ImageNet [9].



Gambar 3. Arsitektur VGG-16

**2.7. Transfer Learning**

Transfer learning adalah metode menggunakan jaringan saraf yang sudah dilatih sebelumnya lalu mengurangi jumlah parameter dengan cara mengambil beberapa bagian dari model yang sudah dilatih untuk digunakan dalam mengenali model baru [10].

**2.8. Confusion Matrix**

Confusion matrix merupakan suatu metode yang digunakan untuk melakukan perhitungan akurasi pada

konsep data mining [11]. Confusion matrix berisikan informasi mengenai hasil klasifikasi aktual dan telah di prediksi oleh sistem klasifikasi. Performa dari sistem tersebut biasanya dievaluasi menggunakan data dalam sebuah matriks. Salah satu Confusion-matrix yang kerap digunakan dalam pengukuran dapat dilihat pada Gambar 4.

		Kejadian Sebenarnya	
		P	N
Hipotesis Kejadian	P	True Positive	False Positive
	N	False Negative	True Negative

Gambar 4. Confusion Matrix

Berdasarkan gambar di atas terdapat beberapa nilai di dalam matriks yaitu “True Positive” (TP), “True Negative” (TN), “False Positive” (FP), dan “False Negative” (FN), seluruh kemungkinan kejadian sebenarnya positif (P) dan seluruh kemungkinan kejadian sebenarnya negatif (N). Nilai tersebut dapat digunakan untuk menghitung akurasi dengan persamaan berikut :

$$Accuracy = \frac{TP + TN}{P + N}$$

Akurasi digunakan sebagai parameter sebagaimana akurat suatu model melakukan klasifikasi. Sementara untuk menghitung tingkat presisi prediksi kejadian dapat digunakan persamaan berikut :

$$Precision = \frac{TP}{TP + FP}$$

Presisi menggambarkan seberapa tepat suatu model memprediksi kejadian positif dalam serangkaian kegiatan prediksi. Perhitungan presisi biasanya bermanfaat pada pengembangan model prediksi hujan di suatu daerah. Selain presisi dan akurasi, untuk dapat melihat lebih detail lagi kinerja suatu sistem, recall atau sensitivitas sistem terhadap suatu kelas juga dapat dilihat. Recall dapat dihitung dengan menggunakan persamaan berikut :

$$Recall = \frac{TP}{TP + FN}$$

**3. METODE PENELITIAN**

Metode yang digunakan untuk menyelesaikan penelitian ini adalah :

a. Dataset

Pada penelitian ini, dataset didapatkan dari situs web Kaggle yang berjumlah 5.245 citra fundus mata dengan format .jpg yang tidak memiliki batasan usia dan jenis kelamin. Dataset tersebut meliputi 237 Age related Macular Degeneration, 262 Katarak, 1.386 Diabetic retinopathy, 218

Glaukoma, 104 Hipertensi okuli, 237 Miopia, 2.816 Normal.

b. *Preprocessing*

Dalam penelitian ini, tahapan *preprocessing* data dimana proses tersebut meliputi rotasi 30°, 45°, 60°, 90° dan refleksi secara vertikal (sumbu x). Kemudian dilakukan pembagian *dataset* sebesar 30% data uji dan 70% data latih.

c. *Transfer Learning*

Dalam tahap ini, akan dilakukan dengan proses *transfer learning* menggunakan model VGG-16 yang sudah *trained* dengan *dataset* ImageNet terhadap data latih.

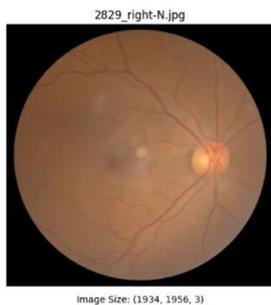
d. *Evaluation*

Pada tahap ini, *dataset* akan diuji dan dievaluasi menggunakan *Confusion Matrix* serta akan dilakukan pengukuran tingkat akurasi.

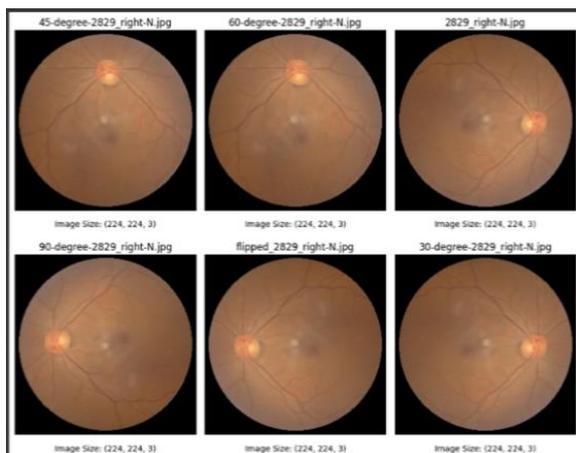
4. HASIL DAN PEMBAHASAN

4.1. *Preprocessing*

Pengambilan *dataset* yang berasal dari Kaggle yang berjumlah 5.245 citra *fundus* mata. Kemudian dilakukan proses *augmentation* maka jumlah *dataset* akan bertambah menjadi 6 kali lipat dikarenakan citra hasil modifikasi dari proses rotasi dan refleksi juga akan ditampung sehingga didapatkan total *dataset* sebanyak 31.560 data.



Gambar 5. Citra Sebelum Preprocessing



Gambar 6. Citra Setelah Preprocessing

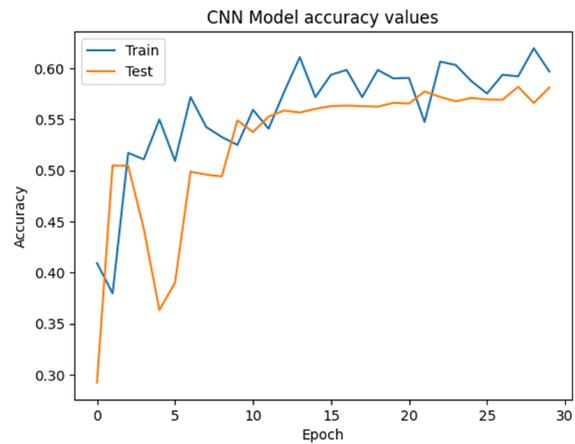
Selanjutnya dilakukan pembagian *dataset*, menjadi 30% data uji dan 70% data latih. Hasil jumlah pembagian *dataset* sebagai berikut yaitu data latih

sebanyak 22.092 data dan data uji sebanyak 9.468 data.

4.2. *Transfer learning*

Setelah dilakukan proses *preprocessing*, selanjutnya data akan melalui proses *transfer learning*.

Proses *transfer learning* dilakukan dengan pelatihan sebanyak 30 kali iterasi (*epoch*) menggunakan data latih sebanyak 22.092 data. Didapatkan grafik pelatihan pada Gambar 7.

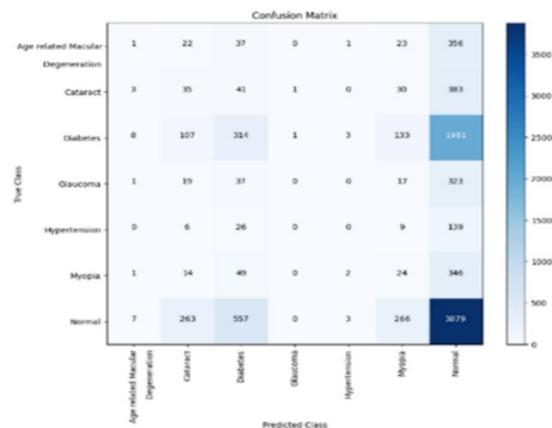


Gambar 7. Grafik Akurasi dan Loss Pada Saat Training

Dalam 30 iterasi (*epoch*) diperoleh akurasi yang didapatkan yaitu sekitar 0,60 yang menunjukkan bahwa model dengan benar memprediksi kelas sekitar 60% dari sampel. Kemudian dilihat dari grafik yang terus menunjukkan peningkatan, sehingga semakin tinggi iterasi yang dilakukan dapat memungkinkan akurasi akan meningkat.

4.3. *Pengujian*

Pengujian model CNN dilakukan dengan menguji model CNN yang sudah dilatih menggunakan data latih yang sudah didapatkan melalui proses pembagian *dataset* dengan jumlah data sebanyak 9.468 citra *fundus* mata dengan menggunakan *Confusion matrix* didapatkan hasil sebagai berikut.



Gambar 7. Output Confusion Matrix

Dapat dilihat bahwa terdapat kelas yang sesungguhnya (*true class*) dan kelas yang diprediksi (*predicted class*). Pada kelas *Normal* terdapat 3.879 data yang terprediksi dengan benar (*true positive*). Jadi kelas *Normal* merupakan kelas yang paling banyak diprediksi dengan benar. Kemudian kelas *Diabetes* terdapat 314 data yang terprediksi dengan benar. Sedangkan kelas yang lain seperti *Age related Macular Degeneration*, *Katarak*, *Glaukoma*, *Hipertensi okuli*, dan *Miopia* masih banyak prediksi-prediksi yang belum benar. Selain itu dari gambar matriks ini dapat diketahui bahwa model yang digunakan cenderung memprediksi kelas *Normal* sehingga pada kelas *Normal* banyak memiliki *false positif*.

Selain itu didapatkan tabel *accuracy*, *precision*, dan *recall* pada Tabel 1.

Tabel 1. Hasil Akurasi Pengujian

	Precision	Recall	F1-score	Support
Age related macular degeneration	0.05	0.00	0.00	440
Cataract	0.08	0.07	0.07	493
Diabetes	0.30	0.12	0.17	2547
Glaucoma	0.00	0.00	0.00	397
Hypertension	0.00	0.00	0.00	180
Myopia	0.05	0.06	0.05	436
Normal	0.52	0.78	0.63	4975
Accuracy			0.45	9468
Macro avg	0.14	0.15	0.13	9468
Weighted avg	0.36	0.45	0.38	9468

*Accuracy* sebesar 0,45 menunjukkan bahwa model dengan benar memprediksi label kelas sekitar 45% dari sampel.

Kelas *Age related Macular Degeneration*, *Glaucoma*, *Hypertension*, *Cataract*, *Myopia* mendapatkan nilai *precision*, *recall*, dan *f1-score* dibawah 0,10. Sehingga model ini dapat diartikan kurang baik dalam memprediksi kelas tersebut.

Kemudian kelas *Diabetes* mendapatkan nilai *precision* sebesar 0,30 *recall* 0,12 *f1-score* 0,17 dengan total data pada kelas ini (*support*) sebanyak 2.547 data sehingga dapat diartikan cukup untuk memprediksi kelas ini.

Kelas *Normal* mendapatkan nilai *precision* sebesar 0,52 *recall* 0,78 *f1-score* 0,63 dengan total data pada kelas ini (*support*) sebanyak 4.975 data sehingga dapat diartikan baik untuk memprediksi kelas ini.

## 5. KESIMPULAN DAN SARAN

Setelah dilakukan penelitian pengklasifikasian citra foto *fundus* menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16 dapat diambil kesimpulan bahwa dengan dilakukan proses *transfer learning* dengan 30 iterasi didapatkan model dengan akurasi sebesar 45%. Hasil yang didapatkan model lebih banyak dan lebih condong memprediksi

dikelas *Normal*. Hal ini dapat dikarenakan jumlah *dataset* kelas *Normal* lebih banyak yaitu 16.896 dari 31.524 data citra atau 53% dari total keseluruhan data citra sehingga dapat diartikan prediksi lebih condong ke kelas *Normal* dibandingkan kelas lain seperti *Age related Macular Degeneration* sebanyak 1.422 data atau 4,5% dari total keseluruhan data, *Katarak* sebanyak 1.572 data atau 4,9% dari total keseluruhan data, *Diabetic retinopathy* sebanyak 8.316 data atau 26% dari total keseluruhan data, *Glaukoma* sebanyak 1.308 data atau 4,1% dari total keseluruhan data, *Hipertensi okuli* sebanyak 624 data atau 1% dari total keseluruhan data citra, dan *Miopia* sebanyak 1.422 data atau 4,5% dari total keseluruhan data. Adapun hasil *precision*, *recall*, dan *f1-score* terendah terdapat pada kelas *Age related Macular Degeneration*, *Glaucoma*, *Hypertension*, *Cataract*, *Myopia* dengan nilai *precision*, *recall*, dan *f1-score* dibawah 0,10. Kemudian kelas *Diabetes* mendapatkan hasil yang cukup dengan *precision* sebesar 0,30 *recall* 0,12 *f1-score* 0,17. Kelas *Normal* mendapatkan hasil yang baik dengan nilai *precision* sebesar 0,52 *recall* 0,78 *f1-score* 0,63.

Adapun saran pada penelitian ini dikarenakan jumlah *dataset* terdapat kelas yang tidak seimbang sehingga hasil prediksinya akan condong ke kelas tersebut sehingga disarankan menyeimbangkan *dataset* dengan mencari data citra baru atau mengurangi jumlah *dataset* pada kelas yang terdapat banyak jumlah *dataset*nya. Selain itu disarankan juga menambah jumlah iterasi pelatihan.

## DAFTAR PUSTAKA

- [1] World Health Organization, *World Report On Vision*. World Health Organization, 2019
- [2] F. Ismandari, *InfoDATIN Gangguan penglihatan*. Jakarta: Kementerian Kesehatan RI, 2018
- [3] S. Cahya, Fani Nurona; Hardi, Nila; Riana, Dwiza; Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *Sist. J. Sist. Inf.*, pp. 618–626, 2021
- [4] B. Handono, Stevanus Frangky; Anggraeny, Fetty Tri; Rahmat, "Implementasi Convolutional Neural Network (CNN) untuk Deteksi Retinopati Diabetik," *J. Inform. dan Sist. Inf.*, pp. 669–678, 2020
- [5] S. A. Fraz, Muhammad Moazam; Paolo, Remagnino; Hoppe, A; Uyyanonvara, Bunyarit; Rudnicka, A. R.; Owen, C G; Barman, "Blood vessel segmentation methodologies in retinal images—a survey," *Comput. Methods Programs Biomed.*, pp. 407–433, 2012
- [6] T. M. Shorten, Connor; Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. big data*, pp. 1–48, 2019
- [7] N. Lever, Jake; Krzywinski, Martin; Altman, "Points of significance: model selection and overfitting," *Nat. Methods*, pp. 703–705, 2016

- [8] D. Ghosh, Anirudha; Sufian, A.; Sultana, Farhana; Chakrabarti, Amian; De, "Recent Trends and Advances in Artificial Intelligence and Internet of Things," in *Fundamental Concepts of Convolutional Neural Network*, Springer, Cham, 2020, pp. 519–567
- [9] A. Simonyan, Karen; Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv Prepr. arXiv1409.1556*, 2014
- [10] M. N. Abas, Mohamad Aqib Haqmi; Ismail, Nurlaila; Yassin, Ahmad Ihsan Mohd; Taib, "VGG16 for plant image classification with transfer learning and data augmentation," *Int. J. Eng. Technol.*, pp. 90–94, 2018
- [11] T. Rosandy, "PERBANDINGAN METODE NAIVE BAYES CLASSIFIER DENGAN METODE DECISION TREE (C4.5) UNTUK MENGANALISA KELANCARAN PEMBIAYAAN (Study Kasus : KSPPS / BMT AL-FADHILA)," *J. TIM Darmajaya*, pp. 52–62, 2016