

# Klasifikasi Penyakit Diabetic Retinopathy Menggunakan Metode CNN Dengan Model Resnet152

1<sup>st</sup> Adisa Salsha Bhiesa  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

adisasalsha@student.telkomuniversity.ac.id

2<sup>nd</sup> Syamsul Rizal, R. Yunendah  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

syamsulrizal@telkomuniversity.ac.id

3<sup>rd</sup> Nur'Fuadah  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

ryunendah@telkomuniversity.ac.id

**Abstrak** — *Diabetic Retinopathy* merupakan salah satu penyakit yang disebabkan oleh diabetes dimana banyaknya jumlah glukosa yang sangat tinggi pada pembuluh darah kapiler kecil yang dapat mengakibatkan pengurangan penglihatan bahkan hingga kebutaan pada penderita. Kadar gula yang tinggi salah satu kondisi yang tidak normal yang terjadi pada tubuh, jika dibiarkan lama kelamaan akan menyebabkan kerusakan pada pembuluh darah halus di kornea mata. Berdasarkan data Badan Kesehatan Dunia (WHO), *Diabetic Retinopathy* adalah penyebab gangguan penglihatan kelima dan penyebab kebutaan keempat di dunia. Pada tahun 2010, kondisi ini dialami oleh 39,3 juta orang di seluruh dunia. Sedangkan di Indonesia, angka kejadian retinopati diabetik pada penderita diabetes sebesar 42,6%. Pada sistem penelitian ini menggunakan metode *Convolutional Neural Network (CNN)* dengan model Resnet152 dan menggunakan dataset sekunder dari website [www.kaggle.com](http://www.kaggle.com) yaitu berasal dari *Aravind Eye Hospital* di India yang digunakan untuk kompetisi *Asia Pasific Tele-Ophthalmology Society (APTOS)* dan dataset berasal dari *GNU Lesser General Public License*. Penelitian ini menggunakan setiap hyperparameter yang terbaik dari *optimizer, learning rate, batch size, dan epoch* menggunakan model Resnet152. *optimizer Adamax, ukuran learning rate 0.001, ukuran batch size 32, dan ukuran epoch 100.*

**Kata kunci** : Convolutional Neural Network (CNN), Diabetic Retinopath, Machine Learning, Resnet152

## I. PENDAHULUAN

*Diabetic Retinopathy* adalah salah satu penyakit mata yang disebabkan oleh diabetes dimana banyaknya jumlah glukosa yang sangat tinggi pada pembuluh darah kapiler kecil yang dapat mengakibatkan pengurangan penglihatan bahkan hingga kebutaan pada penderita. Kadar gula yang tinggi salah satu kondisi yang tidak normal yang terjadi pada tubuh, jika dibiarkan lama kelamaan akan menyebabkan kerusakan pada pembuluh darah halus di kornea mata. Ketika pembuluh darah halus sudah rusak, maka pembuluh darah akan mengeluarkan cairan dan menyebabkan *connon-wall spots*[1].

Berdasarkan data Badan Kesehatan Dunia (WHO), *Diabetic Retinopathy* adalah penyebab gangguan penglihatan kelima dan penyebab kebutaan keempat di dunia. Pada tahun 2010, kondisi ini dialami oleh 39,3 juta orang di seluruh dunia. Sedangkan di Indonesia, angka kejadian retinopati diabetik pada penderita diabetes sebesar 42,6%.[2]. Pengembangan sistem ini berbasis

Mechinea Learning yang menggunakan *Convolutional Neural Network (CNN)*. sistem ini dapat medeteksi pada *Diabetic Retonopaty* dengan akurasi cukup tinggi. Metode ini telah dapat membantu tenaga medis dalam mengidentifikasi tingkat penyakit pada pasien dari normal hingga parah.

## II. KAJIAN TEORI

### A. Diabetic Retinopathy

*Diabetic Retinopathy* adalah salah satu penyakit mata yang disebabkan oleh diabetes dimana banyaknya jumlah glukosa yang sangat tinggi pada pembuluh darah kapiler kecil yang dapat mengakibatkan pengurangan penglihatan bahkan hingga kebutaan pada penderita. Kadar gula yang tinggi salah satu kondisi yang tidak normal yang terjadi pada tubuh, jika dibiarkan lama kelamaan akan menyebabkan kerusakan pada pembuluh darah halus di kornea mata. Ketika pembuluh darah halus sudah rusak, maka pembuluh darah akan mengeluarkan cairan dan menyebabkan *connon-wall spots* [1].

### B. Convolutional Neural Network

*CNN (Convolutional Neural Network)* adalah jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk grid, seperti citra dan video. *CNN* memiliki lapisan-lapisan konvolusi yang secara otomatis dapat mengekstraksi fitur-fitur penting dari data input, sehingga sangat efektif dalam tugas-tugas pengenalan pola visual dan analisis gambar.[3]

### C. Python

Python adalah salah satu bahasa pemrograman tingkat tinggi yang dimana banyak digunakan oleh programmer saat ini. Bahasa pemrograman ini memiliki banyak *library* yang dimana dapat membantu programmer dalam membuat sesuatu pemrograman, oleh sebab itu bahasa pemrograman python ini memiliki fleksibilitas yang sangat tinggi dalam pengembangan mechine learning

### III. METODE

#### A. Dataset

Dataset yang digunakan pada penelitian ini menggunakan dataset sekunder campuran berasal dari website Kaggle, yaitu berasal dari *Aravind Eye Hospital* di India yang digunakan untuk kompetisi *Asia Pasific Tele-Ophthalmology Society (APTOS)*. Dataset berupa *APTOS 2019 Blindness Detection 224x224* [4] dan dataset berasal dari *GNU Lesser General Public License* [5].

TABEL 1  
Daftar Pembagian Dataset

Level	Aptos 2019 Blindness Detection 224x224	GNU Lesser General Public License	Total Images
N0_DR	1805 images	0 images	1805 images
Mild_DR	370 images	1430 images	1800 images
Moderate_DR	999 images	0 images	999 images
Severe_DR	193 images	870 images	1063 images
Proliferaate_DR	295 images	700 images	995 images
Total Images			6.662 images

#### B. PRE-PROCESSING

Sebelum memasuki pelatihan, dataset yang sudah ada akan diubah ukurannya menjadi 224x224 dan dilakukan *splitdata* agar tidak mencegah *overfitting* pada proses pelatihan. Proses ini bertujuan untuk membagikan penggunaan dataset yang akan terbagi menjadi 70% data train sebesar 4.662 gambar, 20% data validation sebesar 1.331 gambar, dan 10% data test sebesar 669 gambar.

#### C. Training

Pada proses Training dalam penelitian ini menggunakan CNN dimana bertujuan menangani data yang terstruktur, untuk kasus saat ini berupa gambar. CNN ini sudah banyak digunakan dalam proses Machine Learning yang dimana bertujuan untuk mengidentifikasi sebuah gambar, objek dan segmentasi sebuah gambar. Salah satu pelopor CNN adalah Yann Lecun, yang menemukan arsitektur yang disebut LeNet-5 pada tahun 1998. LeNet-5 dirancang dengan ukuran input 32x32 piksel, dan terdiri dari 5 lapisan CNN. Tujuan awalnya adalah untuk mengenali digit dalam kode pos [6].

#### D. Resnet152

ResNet-152 adalah salah satu arsitektur jaringan saraf konvolusi yang sangat dalam dan kuat. Dikembangkan oleh Kaiming He et al., ResNet-152 mengandalkan blok residu untuk mengatasi tantangan dalam melatih jaringan yang sangat dalam. Dengan 152 lapisan, arsitektur ini mampu menghasilkan representasi hierarkis yang semakin kompleks dan abstrak dari data visual [7].

TABEL 2  
Layer Sistem Model

Layer (type)	Output Shape	Param
Resnet152	(None, 2048)	58370944
Dropout	(None, 2048)	0
Dense	(None, 128)	262272
Dropout1	(None, 128)	0
Dense 1	(None, 64)	8256
Dropout2	(None, 64)	0
Dense 2	(None, 32)	2080
Dropout3	(None, 32)	0
Flatten	(None, 32)	0
Dense3	(None, 5)	165

Tabel 2 menampilkan arsitektur yang digunakan pada percobaan kali pada penelitian saat ini untuk mengidentifikasi tingkatan penyakit *Diabetic Retonopathy*.

#### E. Pengujian Parameter

Parameter yang diuji dalam penelitian saat ini terdapat 4 parameter yaitu *Batch* (8, 16, 32, 64), *Optimizer* (Adam, Adamax, SGD, RMSprop), dan *Learning Rate* (0.1, 0.01, 0.001, 0.0001), dan jumlah *epoch* (50, 100, 150, 200). Pada pengujian batch ukuran batch dalam pelatihan model machine learning merujuk pada jumlah sampel data yang digunakan dalam satu iterasi proses pelatihan. Ukuran batch dapat bervariasi tergantung pada ukuran dataset, kapasitas memori komputer, dan efisiensi komputasi yang diinginkan. Pemilihan ukuran batch yang tepat dapat mempengaruhi kecepatan konvergensi dan stabilitas model [8]. Optimizer dalam konteks *machine learning* merujuk pada algoritma yang digunakan untuk mengoptimasi model dalam proses pelatihan. Tujuannya adalah untuk menyesuaikan parameter model agar dapat mengurangi nilai *loss* atau *error* sebanyak mungkin. Optimizer melakukan ini dengan mengatur perubahan bobot dan bias dalam jaringan saraf atau model lainnya berdasarkan gradien *loss* terhadap parameter-parameter tersebut [9]. Learning rate dalam konteks machine learning merujuk pada ukuran langkah yang diambil oleh algoritma optimasi saat mengupdate parameter-model dalam setiap iterasi pelatihan. *Learning rate* mengontrol seberapa besar atau kecil perubahan yang akan diterapkan pada parameter-model setelah setiap iterasi. Nilai *learning rate* yang tepat sangat penting, karena nilai yang terlalu besar dapat menyebabkan pelatihan tidak stabil atau bahkan menyebabkan model tidak konvergen, sedangkan nilai yang terlalu kecil dapat membuat pelatihan berlangsung sangat lambat [10]. *Epoch* dalam konteks machine learning merujuk pada satu putaran penuh dari seluruh dataset pelatihan yang digunakan untuk melatih model. Saat melatih sebuah model, data pelatihan dibagi menjadi beberapa batch, dan setiap batch digunakan untuk mengupdate parameter-model dalam satu iterasi. Setelah semua batch telah digunakan dan model telah diperbarui, satu epoch dianggap selesai. Jumlah epoch yang dipilih dapat bervariasi tergantung pada kompleksitas dataset dan model yang digunakan. [11]. Uji coba yang dilakukan dengan cara menggabungkan parameter yang ada dengan membandingkan hasil tiap parameter yang telah diuji dan kemudian hasil terbaik akan diterapkan pada model yang sudah ada.

IV. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset sekunder yang didapatkan dari APTOS 2019 *Blindness Detection 224x224* [5] dan dataset berasal dari GNU *Lesser General Public License* [6]. Yang dimana mengandung jumlah 6.662 gambar dataset yang terdiri dari 1.805 gambar No\_DR, 1.800 gambar Mild\_DR, 999 gambar Moderate\_DR, 1.063 gambar Severe\_DR, dan 995 gambar Prolifera DR dengan pembagian 70% data train, 20% validation dan 10% test. Percobaan yang terjadi pada penelitian ini mengarah kepada hyperparameter, dimana dapat ditarik hasil terbaik yang didapat dari model yang sudah dilatih yang dimana dalam hasil pelatihan tersebut menghasilkan grafik, laporan klasifikasi dan *confusion matrix*. Dengan hasil penelitian tersebut, model yang didapat kemudian dilakukan testing yang dimana dari pembagian data sebelumnya yang sebanyak 669 data yang digunakan pada testing ini. Pada hasil pengujian model tersebut akan didapatkan *confusion matrix* sebagai bahan acuan untuk mendapatkan model yang terbaik. Berikut adalah lampiran hasil pengujian model yang didapat.


```

21/21 [=====] - 7s 221ms/step
                precision    recall  f1-score   support

   Mild         0.79      0.82      0.81       101
  Moderate     0.97      0.98      0.98       181
   No_DR       0.73      0.78      0.76       180
Prolifera DR  0.50      0.51      0.51       107
   Severe_DR   0.61      0.48      0.54       100

 accuracy                    0.75       669
 macro avg                 0.72      0.72      0.72       669
 weighted avg              0.75      0.75      0.75       669
    
```

GAMBAR 3 Hasil Presisi, Recall, F1-score




GAMBAR 4 Hasil Confusion Matrix Terbaik


```

array([[ 83,  2, 13,  3,  0],
       [  0, 178,  3,  0,  0],
       [  7,  3, 141, 19, 10],
       [ 10,  0,  21, 55, 21],
       [  5,  0,  14, 33, 48]])
    
```

GAMBAR 5 Array Confusion Matrix Terbaik



GAMBAR 1 Hasil Akurasi Terbaik



GAMBAR 2 Hasil Loss Terbaik

Dari gambar 1, 2, 3, 4, dan 5 mendapatkan hasil penelitian akurasi sebesar 75% dengan hasil hasil presisi 75%, *recall* 72%, dan *F1-score* 72%. Dari hasil dan grafik diatas dapat disimpulkan bahwa hasil dari model tersebut masih overfitting, dimana dari hasil tersebut masih dapat dikembangkan lagi dengan cara normalisasi dataset maupun melakukan dropout dan sejenisnya untuk mendapatkan hasil yang maksimal, namun untuk parameter yang digunakan sudah cukup maksimal dalam mendapatkan hasil saat ini.

V. KESIMPULAN

Dari hasil penelitian diatas dapat ditarik kesimpulan klasifikasi penyakit Diabetic Retinopathy menggunakan CCN dengan model Resnet152 dengan pengujian 4 parameter berupa *batch*, *optimizer*, dan *Learning Rate*, dan *epoch*. Dengan hasil penelitian tersebut tiap pengujian parameter memiliki hasil optimal pada tiap parameter. Untuk batch dari pengujian 8, 16, 32, dan 64 mendapatkan hasil yang maskimal pada ukuran batch 32. Untuk pengujian pada optimizer yang sudah dilakukan dari Adam, Adamax, SGD, dan RMSprop medanaptnkan kesimpulan Adamx memiliki hasil akurasi yang paling optimal. Untuk Learning Rate yang

dilakukan pada penelitian ini dari 0.1, 0.01, 0.001, dan 0.0001 mendapatkan hasil optimal pada 0,001. Untuk hasil pengujian jumlah epoch dari pengujian 50, 100, 150, dan 200 mendapatkan hasil terbaik pada 100 batch. Dari penelitian tersebut mendapatkan akurasi sebesar 75% dengan hasil presisi 75%, recall 72%, dan F1-score 72%. Dari hasil dan grafik diatas dapat disimpulkan bahwa hasil dari model tersebut masih *overfitting*.

#### REFERENSI

- [1] E. V. Carrera, A. Gonzalez, and R. Carrera, "Automated detection of Diabetic Retinopathy using SVM," Proc. 2017 IEEE 24th Int. Congr. Electron. Electr. Eng. Comput. INTERCON 2017, pp. 6–9, 2017, doi: 10.1109/INTERCON.2017.8079692.
- [2] G. Information, "Diabetic Retinopathy - Asia," pp. 1–17, 2016.
- [3] LeCun, Y., LeCun, Y. Bengio, and G. Hinton, "Deep Learning," Nature, vol. 521, no. 7553, pp. 436–444, May 2015, doi: <https://doi.org/10.1038/nature14539>.
- [4] S . R. Rath, "Diabetic Retinopathy 224x224 (2019 Data)," Kaggle, 2020.
- [5] S.Kumar, "Diabetic Retinopathy Preprocessed Dataset ," Kaggle, 2022.
- [6] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," Proceedings of the IEEE, vol. 86, no. 11, pp. 2278–2324, 1998, doi: <https://doi.org/10.1109/5.726791>.
- [7] K . He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778, Jun. 2016, doi: <https://doi.org/10.1109/cvpr.2016.90>
- [8] Klaus-Robert Müller, "Speeding Learning," Lecture Notes in Computer Science, pp. 7–8, Jan. 2012, doi: [https://doi.org/10.1007/978-3-642-35289-8\\_2](https://doi.org/10.1007/978-3-642-35289-8_2).
- [9] D . P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," arXiv.org, Dec. 22, 2014. <https://arxiv.org/abs/1412.6980>
- [10] S . Ruder, "An overview of gradient descent optimization algorithms," arXiv.org, 2016. <https://arxiv.org/abs/1609.04747>.
- [11] M . A. Nielsen, Neural Networks and Deep Learning. Determination Press, 2015. Accessed: Aug. 17, 2023. [Online]. Available: [https://books.google.co.id/books/about/Neural\\_Networks\\_and\\_Deep\\_Learning.html?id=STDBswEACAAJ&redir\\_esc=y](https://books.google.co.id/books/about/Neural_Networks_and_Deep_Learning.html?id=STDBswEACAAJ&redir_esc=y).