

Klasifikasi *Severity Level Diabetic Macular Edema* Berbasis ResNet-50

I Md. Dendi Maysanjaya*, Putu Yudia Pratiwi, I Gusti Ayu Agung Diatri Indradewi

Prodi Sistem Informasi, Universitas Pendidikan Ganesha, Jln. Udayana No. 11, Singaraja, 81116, Indonesia

Informasi Naskah:

Diterima: 29 September 2025/ Direview: 02 Januari 2026/ Direvisi: 19 Februari 2026/ Disetujui Terbit: 20 Februari 2026

DOI: 10.33369/pseudocode.13.1.9-13

*Korespondensi: dendi.ms@undiksha.ac.id

Abstract

Diabetes is one of the most common diseases people suffer from today, and it can lead to complications such as blindness, heart disease, and kidney failure. The condition of blindness caused by this disease is known as diabetic retinopathy (DR). An ophthalmologist will use a fundus camera to examine the retina, looking for several clinical features, such as microaneurysms (MA), hemorrhages (HM), cotton-wool spots (CWS), and exudates. Based on these clinical symptoms, clinicians then determined the patient's level of diabetic macular edema (DME) severity. Although several studies have applied CNN-based architectures for diabetic retinopathy detection, limited attention has been given to the impact of dataset imbalance handling on DME severity classification, particularly using ResNet-50. This study highlights the significant impact of extensive data augmentation on classification performance in imbalanced DME datasets. Evaluate performance using the accuracy, precision, and recall metrics. We used the IDRiD dataset, which consists of 516 images split into a training set of 413 and a test set of 103. IDRiD divides the dataset into three classes, namely normal, moderate DME, and severe DME. In the preprocessing stage, we enhanced contrast using CLAHE and resized the images to 224x224 pixels. To address the imbalance, we applied 11 data augmentation methods. We experimented by comparing the performance of two models: one with and one without dataset augmentation. Based on the test results, the best performance was obtained with the model that included dataset augmentation, achieving an accuracy of 0.5961, a precision of 0.63, and a recall of 0.61, while the baseline model (without dataset augmentation) gained 0.4553, 0.36, and 0.34 for the accuracy, precision, and recall, respectively.

Keywords: classification; severity level; diabetic macular edema; ResNet-50.


1. Pendahuluan

Diabetes merupakan salah satu permasalahan utama yang sering terjadi di negara berkembang. *The World Diabetes Foundation* memprediksi bahwa lebih dari 439 juta jiwa terancam menderita diabetes pada tahun 2030 [1]. Hal ini disebabkan oleh pertumbuhan populasi serta obesitas yang diakibatkan gaya hidup tidak sehat. Efek jangka panjang yang diakibatkan oleh penyakit diabetes adalah kerusakan pembuluh darah pada retina mata, yang dikenal dengan istilah *diabetic retinopathy* (DR) [2]. DR merupakan salah satu jenis penyakit kronis pada mata yang menyebabkan kebutaan, dengan penderita dominan berada pada kisaran umur 20 hingga 74 tahun.

International Diabetes Management Practices Study, menyatakan bahwa terdapat 34,6% penderita DR merupakan populasi dari penderita Diabetes Melitus. Diperkirakan 8,8 juta orang yang terkena diabetes di Indonesia, dan diprediksi akan meningkat menjadi 21,3 juta di tahun 2030. Pada penderita DR, pemeriksaan fundus mata yang teratur sangat penting, diikuti dengan perawatan laser yang sesuai jika diperlukan. Hal ini bertujuan untuk mencegah komplikasi semakin parah. Oleh karenanya deteksi dan diagnosis dini sangat diperlukan untuk mengimbangi laju perkembangan penyakit ini [2] [3] [4] [5] [6].


Diabetic retinopathy secara umum diklasifikasikan menjadi dua jenis, yakni *non-proliferative diabetic*

retinopathy (NPDR) dan *proliferative diabetic retinopathy* (PDR). NPDR dapat dibagi menjadi tiga sub kelas, yakni *mild NPDR*, *moderate NPDR*, serta *severe NPDR* [7][8]. Sub kelas ini dapat diidentifikasi berdasarkan dari ada tidaknya ciri klinis, yaitu *microaneurysms*, *haemorrhages*, *cotton wool spots* (kadang dikenal juga dengan istilah *soft exudates*), *hard exudates*, *neovascularization*, dan *macular edema* seperti yang ditunjukkan pada Gbr. 1.



Gbr. 1. Ciri Klinis Kasus Diabetic Retinopathy [9]

Dalam klasifikasi *severity level* penyakit DR terbagi menjadi lima kategori diantaranya yaitu tingkat normal dengan tidak terdapat tanda kelainan *retinopathy* pada mata, tingkat *Mild Non-Proliferative Diabetic retinopathy* (NPDR) yang memiliki ciri-ciri hanya terdapat microaneurysms (MA), tingkat *Moderate NPDR* dengan ciri-ciri lebih dari sekedar microaneurysms (MA) tetapi kurang dari *Non-Proliferative Diabetic retinopathy* (NPDR) yang parah, tingkat *Severe NPDR* dengan ciri-ciri terdapat lebih dari 20 *Hemorrhages* (HE) *intraretinal* atau terdapat bercak manik-manik vena atau terdapat kelainan *mikrovaskular intraretinal* atau tidak ada tanda-tanda *Proliferative Diabetic Retinopathy* (PDR), tingkat *Proliferative Diabetic retinopathy* (PDR) dengan ciri-ciri terdapat neovaskularisasi dan/atau HE *vitreous/pra-retina* [10], [11]. Berdasarkan kelima tingkat penyakit DR ini, akan berkorelasi terhadap munculnya *diabetic macular edema* (DME) yang terbagi menjadi kelas non-DME, *mild*, dan *severe*. Contoh citra untuk ketiga kelas DME dapat dilihat pada Gbr. 2.



Gbr. 2. (a) non DME, (b) *mild* DME, (c) *severe* DME [12]

Porwal, *et al*, [10] menyatakan bahwa banyak orang yang memerlukan tindak lanjut secara terus-menerus sehingga proses penanganan penyakit DR memerlukan perhatian untuk pengembangan alat diagnosis berbantuan komputer atau *computer aided diagnosis* (CAD). Perkembangan teknologi berbasis *computer aided diagnosis* (CAD) ditujukan untuk membantu dalam mendiagnosis dan mengklasifikasikan *severity level* DME. Pengklasifikasian tersebut sangat membantu proses indikasi dari penyakit DME yang diderita oleh pasien sehingga memudahkan *ophthalmologist* dalam mengenali *severity level* DME. Hal ini didukung juga oleh berbagai perkembangan metode kecerdasan buatan, khususnya pengembangan *deep learning*, yang bisa digunakan untuk melakukan klasifikasi ini. Contoh metode yang sering digunakan adalah *Convolutional Neural Network* (CNN), yang saat ini dikombinasikan dengan beragam arsitektur seperti AlexNet, *Residual Network* (ResNet), GoogleNet, DenseNet, Inception, VGG-Net, dan MobileNet [13], [14], [15], [16], [17].

Sebagai upaya dalam pengembangan keilmuan, khususnya implementasi keilmuan informatika pada bidang medis (dalam hal ini untuk kasus DR dan DME), maka melalui penelitian ini fokus pada aspek peningkatan jumlah *dataset* melalui skema augmentasi citra serta melakukan beberapa *fine tuning parameter* untuk arsitektur ResNet-50 yang digunakan, sehingga diharapkan melalui skema ini bisa memberikan kontribusi terhadap penelitian yang sudah ada terkait klasifikasi DME.


2. Metodologi Penelitian

Tujuan dari penelitian ini adalah mengimplementasikan ResNet-50 untuk mengklasifikasi *severity level* kasus *Diabetic*

Macular Edema pada citra fundus retina. Pada bagian ini dipaparkan sub bagian terkait alur eksperimen, *dataset*, ResNet-50, serta diakhiri paparan terkait parameter evaluasi.

2.1. Alur Eksperimen

Secara umum penelitian ini terbagi menjadi tahap kajian pustaka dan identifikasi masalah, akuisisi *dataset*, pemodelan, pengujian, serta penarikan simpulan. Untuk pemodelan yang dilakukan, alur eksperimen dapat dilihat pada Gbr. 2.



Gbr. 2. Alur Eksperimen

Adapun penjelasan tahapan alur eksperimen pada Gbr. 2. adalah sebagai berikut.


- 1) Dataset setelah diakuisisi dari sumber, selanjutnya dibagi dengan proporsi 80% data latih dan 20% data uji. Kemudian ukuran dari citra asli disesuaikan dengan kebutuhan dari arsitektur ResNet-50.
- 2) Selanjutnya untuk data latih dikenakan beberapa proses augmentasi, yang bertujuan untuk meminimalisir terjadinya kasus *imbalance dataset*, khususnya pada data latih. Pada tahap ini dirancang dua skenario pengujian untuk mengukur pengaruh serta efektivitas dari proses *balancing dataset*.
- 3) Pada tahap pemodelan difokuskan untuk menentukan beberapa pengaturan nilai *hyperparameter*, dengan tujuan untuk mendapatkan hasil klasifikasi yang optimal
- 4) Tahap berikutnya adalah melakukan pengujian terhadap beberapa model yang dirancang, serta dilakukan perbandingan terhadap hasil yang diperoleh
- 5) Pengujian model diukur berdasarkan tiga jenis parameter, yakni akurasi, *precision*, serta *recall*.
- 6) Tahap terakhir melakukan analisis terkait kondisi-kondisi yang mempengaruhi hasil tersebut.

2.2. Dataset

Data yang digunakan pada penelitian ini adalah citra fundus retina mata untuk kasus penderita DR. *Dataset* akan menggunakan data sekunder, yang akan diakuisisi dari *Indian Diabetic Retinopathy Images Dataset* (IDRID) [12]. Total citra yang akan diakuisisi berjumlah 516 citra, yang terdiri atas 413 citra sebagai data latih (80%) dan 103 citra sebagai data uji (20%). Citra ini memiliki resolusi 4288 x 2848 piksel, dengan kedalaman warna 24 bit (RGB), serta berformat JPG. Rincian jumlah *dataset* untuk masing-masing kelas tersaji pada Tabel 1 dan Gbr. 3 merupakan contoh sampel dari *dataset* yang akan diakuisisi dari IDRID.

Tabel 1. Rincian Jumlah Citra Tiap Kelas

DME Grade	Train Set	Test Set
Normal (0)	177	45
Moderate (1)	41	10
Severe (2)	195	48
Total	413	103



Gbr. 3. Sampel Citra Fundus Retina

2.3. ResNet-50

Residual Neural Network (ReNet) 50 merupakan varian dari arsitektur *Residual Network*, yang dikenalkan pertama

kali oleh He, *et al*, [18]. Model arsitektur ini memiliki hingga 50 lapisan, termasuk 48 lapisan konvolusi, satu lapisan *max pooling*, dan satu lapisan *average pooling*. Jumlah *floating-point* hingga $3,8 \times 10^9$. Lapisan konvolusi ResNet-50 menggunakan filter berukuran 3x3 piksel, serta *input size* berukuran 224x224. Setiap lapisan dalam model memiliki jumlah filter dan keluaran yang sama. Saat jumlah filter berlipat ganda, ukuran keluaran data yang dikonvolusi berkurang setengahnya. Jaringan diakhiri dengan lapisan *average pooling*, diikuti oleh lapisan *fully-connected* dengan 1.000 node yang menggunakan fungsi aktivasi softmax [19].

2.4. Parameter Evaluasi

Pada penelitian ini menggunakan tiga jenis parameter evaluasi untuk mengukur performa klasifikasi, yakni akurasi, *precision*, dan *recall*. Akurasi bertujuan untuk mengukur proporsi hasil yang diprediksi dengan benar, terutama ketika data terdistribusi merata di antara kelas yang berbeda. *Precision* adalah proporsi jumlah data positif yang diprediksi dengan benar dari seluruh data yang diprediksi positif, sedangkan *recall* mengacu pada proporsi jumlah data positif yang diprediksi dengan benar dari seluruh data positif yang seharusnya. Persamaan yang digunakan untuk menghitung akurasi, *precision*, dan *recall* secara berurutan yakni (1), (2), dan (3).

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

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

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

3. Hasil dan Pembahasan

Berdasarkan hasil akuisisi *dataset*, tahap pertama yang dilakukan adalah melakukan peningkatan kualitas citra serta pengaturan resolusi citra. Peningkatan kualitas citra dilakukan dengan mengimplementasikan metode CLAHE, sedangkan resolusi yang digunakan yakni 224x224 piksel, sesuai kebutuhan arsitektur ResNet-50.

Setelah melalui tahap peningkatan kualitas citra, selanjutnya dilakukan tahap augmentasi citra dilakukan untuk meminimalisir kondisi *imbalanced dataset*, khususnya jumlah citra latih. Proses augmentasi yang dilakukan dengan melakukan *oversampling* terhadap beberapa jenis augmentasi. Terdapat 11 jenis proses augmentasi yakni *horizontal flip*, *vertical flip*, enam variasi *random rotation* (rotasi sudut: 30 derajat, 60 derajat, 90 derajat, 120 derajat, 150 derajat, dan 210 derajat). Selanjutnya, pengaturan *random brightness*, *random CLAHE*, serta *Gauss Noise*. Adapun perbandingan jumlah data sebelum dan setelah proses augmentasi ditampilkan pada Tabel 2.

Tabel 2. Perbandingan Jumlah Data Latih Sebelum dan Setelah Augmentasi

DME Grade	Sebelum	Setelah
Normal (0)	177	938
Moderate (1)	41	840
Severe (2)	195	952
Total	413	2730

Dasar pemilihan augmentasi citra sebagai alternatif untuk meningkatkan jumlah *dataset* dipengaruhi beberapa faktor, yakni bertujuan untuk memberikan varians stokastik sehingga memaksa model untuk belajar fitur *invariant*. Selain itu augmentasi juga mampu mensimulasikan variabilitas kondisi di lapangan/dunia nyata, sehingga meningkatkan generalisasi yang tidak bisa dilakukan jika hanya mengubah bobot *loss function*.

Meskipun augmentasi memiliki keunggulan bisa menambah varians mendekati kondisi dunia nyata, namun perlu diperhatikan juga potensi terjadinya *data leakage*. Kondisi ini akan menyebabkan nilai akurasi relatif tinggi, namun cukup sulit untuk diuji pada kasus baru. Oleh karena itu, untuk meminimalisir terjadinya potensi *data leakage* akibat proses augmentasi, pada penelitian ini fokus melakukan augmentasi pada data latih, sedangkan pada data uji tidak dilakukan augmentasi. Selain itu, jenis augmentasi yang dilakukan dibuat senatural mungkin dengan kondisi-kondisi yang terjadi di dunia nyata.

Setelah proses augmentasi dan *balancing dataset*, proses berikutnya adalah membangun model latih. Arsitektur yang digunakan dalam membanting model latih yakni ResNet-50. Adapun pengaturan *hyperparameter* terhadap model yang dibentuk dapat dilihat pada Tabel 3.

Tabel 3. Pengaturan *Hyperparameter* ResNet-50

Parameter	Deskripsi
Batch Size	32
Dropout	0,5
Learning Rate	0,0001
Epoch	100
Step per Epoch	149
Callback	10
Dense	1024
Input Resolution	224x224
Loss Function	Cross-entropy
Optimizer	Adam
Weight	Imagenet

Berdasarkan pengaturan pada Tabel 3, *fine-tuning* dilakukan secara parsial (tidak dilakukan pada semua *layer*). Hal ini bertujuan untuk menjaga stabilitas fitur dasar serta meminimalisir terjadinya *overfitting*. Selanjutnya *dropout* ditempatkan sebelum *fully-connected layer* untuk mencegah ketergantungan antar neuron. Jumlah *node* yang digunakan sebanyak 1024 *node*, bertujuan untuk memastikan model memiliki kapasitas yang cukup dalam membedakan fitur patologis yang kompleks sebelum dilakukan klasifikasi akhir.

Pada tahap pengujian, dirancang dua model eksperimen yakni membandingkan antara model yang tanpa menggunakan augmentasi dengan model yang menggunakan tambahan augmentasi. Hal ini bertujuan untuk mengukur efektivitas augmentasi yang dilakukan terhadap hasil klasifikasi. Adapun hasil pengujian dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Hasil Pengujian Kedua Model

Skenario	Train		Test		Precision	Recall
	Loss	Acc	Loss	Acc		
Model A	0.2241	0.9695	2.1106	0.4553	0.36	0.34
Model B	0.0701	0.9824	1.6914	0.5961	0.63	0.61

Ket:
Model A: tanpa augmentasi
Model B: dengan augmentasi

Berdasarkan hasil pengujian pada Tabel 3, terlihat bahwa proses augmentasi memiliki pengaruh signifikan terhadap peningkatan nilai akurasi, *precision*, serta *recall*. Nilai akurasi mengindikasikan kemampuan model yang dihasilkan mampu mengklasifikasi *severity level* kasus DME, sedangkan peningkatan nilai *precision* dan *recall* mengindikasikan bahwa kondisi *overfitting* yang terjadi relatif membaik, daripada model yang tidak dikenakan proses augmentasi.

Jika dilihat secara kualitas, nilai akurasi, presisi, dan *recall* yang dihasilkan relatif tergolong rendah. Hal ini disadari merupakan sebuah tantangan yang cukup memerlukan perhatian lebih, mengingat beberapa faktor yang mempengaruhi kualitas model, seperti kondisi keterbatasan *dataset* yang dijadikan acuan pada proses augmentasi, sehingga varians citra augmentasi yang dihasilkan kurang optimal dalam meningkatkan kualitas *dataset*. Selain itu, jumlah varians *intra-class*, khususnya kelas *moderate*, dibandingkan kelas yang lain yang cukup jauh, sehingga hal ini berpengaruh terhadap kualitas model dalam membedakan ketiga kelas ini.

4. Kesimpulan

Secara umum penelitian ini bertujuan untuk mengklasifikasi *severity level* kasus DME pada citra fundus retina mata. *Dataset* yang digunakan dari IDRiD *dataset*, yang terdiri atas 516 citra, dengan pembagian 80% data latih (413 citra) dan 20% data uji (103 citra). Klasifikasi melibatkan arsitektur ResNet-50, dengan dua skema eksperimen yakni dengan dan tanpa augmentasi *dataset*. Berdasarkan pengujian yang dilakukan, model dengan tambahan augmentasi menghasilkan performa lebih baik daripada yang tidak

menggunakan augmentasi, dengan perolehan nilai akurasi sebesar 0,5961, *precision* sebesar 0,63, dan *recall* sebesar 0,61.

Pengembangan hasil penelitian ini yang bisa dilakukan kedepannya adalah mengoptimalkan proses augmentasi *dataset* dengan mempertimbangkan eksperimen dengan metode *generative adversarial network* (GAN), sehingga varians dari *dataset* bisa lebih beragam.

Referensi

- [1] V. M. Mane and D. V. Jadhav, "Progress towards automated early stage detection of diabetic retinopathy: Image analysis systems and potential," *Journal of Medical and Biological Engineering*, vol. 34, no. 6, pp. 520–527, 2014, doi: 10.5405/jmbe.2060.
- [2] H. A. Nugroho, K. Z. W. Oktoeberza, T. B. Adji, and M. B. Sasongko, "Segmentation of exudates based on high pass filtering in retinal fundus images," *Proceedings - 2015 7th International Conference on Information Technology and Electrical Engineering: Envisioning the Trend of Computer, Information and Engineering, ICITEE 2015*, pp. 436–441, 2015, doi: 10.1109/ICITEED.2015.7408986.
- [3] H. A. Nugroho, W. K. Z. Oktoeberza, A. Erasari, A. Utami, and C. Cahyono, "Segmentation of optic disc and optic cup in colour fundus images based on morphological reconstruction," *2017 9th International Conference on Information Technology and Electrical Engineering, ICITEE 2017*, vol. 2018-Janua, pp. 1–5, 2017, doi: 10.1109/ICITEED.2017.8250456.
- [4] World Health Organization, "Blindness and vision impairment," Oct. 2022, [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>
- [5] S. Qummar *et al.*, "A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection," *IEEE Access*, vol. 7, pp. 150530–150539, 2019, doi: 10.1109/ACCESS.2019.2947484.
- [6] Aswhaty K.P and D. V. Kumar, "Diabetic Retinopathy Detection Using Semantic Segmentation And Optic Disc Localization," *Turkish Journal of Computer and Mathematics Education*, vol. 12, no. 9, pp. 305–311, 2021.
- [7] M. R. K. Mookiah, U. R. Acharya, C. K. Chua, C. M. Lim, E. Y. K. Ng, and A. Laude, "Computer-aided diagnosis of diabetic retinopathy: A review," *Computers in Biology and Medicine*, vol. 43, no. 12, pp. 2136–2155, 2013, doi: 10.1016/j.compbimed.2013.10.007.
- [8] F. of M. Department of Ophthalmology & Visual Sciences The University of British Columbia, "Color Fundus Photography," 2023, [Online]. Available: <https://ophthalmology.med.ubc.ca/patient-care/ophthalmic-photography/color-fundus-photography/>
- [9] G. E. Associates, "Glaucoma," 2021, [Online]. Available: <https://gadsdeneye.com/glaucoma/>
- [10] P. Porwal *et al.*, "IDRiD: Diabetic Retinopathy – Segmentation and Grading Challenge," *Medical Image Analysis*, vol. 59, 2020, doi: 10.1016/j.media.2019.101561.
- [11] D. Lokuarachchi, K. Gunarathna, L. Muthumal, and T. Gamage, "Automated Detection of Exudates in Retinal Images," *Proceedings - 2019 IEEE 15th International Colloquium on Signal Processing and its Applications, CSPA 2019*, no. March, pp. 43–47, 2019, doi: 10.1109/CSPA.2019.8696052.
- [12] P. Porwal *et al.*, "Indian diabetic retinopathy image dataset (IDRiD): A database for diabetic retinopathy screening research," *Data*, vol. 3, no. 3, pp. 1–8, 2018, doi: 10.3390/data3030025.
- [13] A. Singh Gautam, S. Kumar Jana, and M. P. Dutta, "Automated diagnosis of diabetic retinopathy using image processing for non-invasive biomedical application," *2019 International Conference on Intelligent Computing and Control Systems, ICCS 2019*, no. Iccics, pp. 809–812, 2019, doi: 10.1109/ICCS45141.2019.9065446.
- [14] R. Vignesh, N. Muthukumaran, and M. P. Austin, "Detection of Diabetic Retinopathy Image Analysis using Convolution Graph Neural Network," presented at the 2023 International Conference on Inventive Computation Technologies (ICICT), 2023, pp. 921–929. doi: 10.1109/ICICT57646.2023.10134388.
- [15] A. O. Asia *et al.*, "Detection of Diabetic Retinopathy in Retinal Fundus Images Using CNN Classification Models," *Electronics (Switzerland)*, vol. 11, no. 17, Sep. 2022, doi: 10.3390/electronics11172740.
- [16] R. Indraswari, W. Herulambang, and R. Rokhana, "Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN) Ocular Disease Detection on Fundus Images Using Convolutional Neural Network (CNN)," *Techno. Com*, vol. 21, no. 2, pp. 378–389, 2022.
- [17] A. Mustapha, L. Mohamed, H. Hamid, and K. Ali, "Diabetic Retinopathy Classification Using ResNet50 and VGG-16 Pretrained Networks," *International Journal of Computer Engineering and Data Science*, vol. 1, pp. 2737–8543, 2021.
- [18] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," presented at the Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, Dec. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [19] R. I. Bendjillali, M. Beladgham, K. Merit, and A. Taleb-Ahmed, "Illumination-robust face recognition based on deep convolutional neural networks architectures," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 18, no. 2, pp. 1015–1027, 2020, doi: 10.11591/ijeecs.v18.i2.pp1015-1027.