

Klasifikasi Penyakit Diabetic Retinopathy Menggunakan Metode CNN Dengan Arsitektur EfficientNetV2s

1st Ilham Mohammad Suryaman
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ilhammsuryaman@student.telkomuniversity.ac.id

2nd Syamsul Rizal
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
syamsul@telkomuniversity.ac.id

3rd R.Yunendah Nur'Fuadah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
yunendah@telkomuniversity.ac.id

Abstrak — Diabetic Retinopathy adalah salah satu komplikasi penyakit yang disebabkan oleh diabetes melitus. Penyakit tersebut dapat mempengaruhi mata penderita diabetes baik secara fisik maupun fungsi dari mata itu sendiri. Penanganan dan diagnosa dini sangat penting untuk mencegah perkembangan penyakit ini. Salah satu metode yang dapat digunakan untuk mendukung diagnosa tersebut adalah dengan menggunakan teknologi pengolahan citra dengan Machine Learning. Penelitian ini bertujuan untuk mengembangkan metode klasifikasi untuk mendeteksi tingkatan penyakit Diabetic Retinopathy dengan menggunakan metode CNN (Convolutional Neural Network) dan menggunakan model arsitektur EfficientNetV2s. Dari penelitian tersebut, dapat disimpulkan bahwa untuk klasifikasi tingkat penyakit Diabetic Retinopathy memiliki tingkat akurasi yang cukup tinggi dengan nilai sebesar 80%, Presisi 77%, Recall 76%, dan F1-Score 76%.

Kata kunci — CNN, Diabetic Retinopathy, EfficientNetV2s

I. PENDAHULUAN

Diabetic Retinopathy merupakan penyakit mata yang diawali oleh diabetes melitus. Diabetic Retinopathy sendiri yaitu penyakit kronis progresif yang berada di pembuluh darah di retina dan memiliki potensi mengancam penglihatan[1]. DR ditandai dengan munculnya titik-titik pada mikroaneurisma (pembuluh darah), kebocoran pembuluh darah, eksudat (bintik-bintik lipid kekuningan), pembengkakan retina, pertumbuhan abnormal pembuluh darah baru, dan rusak jaringan saraf [2]. DR diklasifikasikan menjadi lima kelas, termasuk tidak ada tanda DR (normal), Non-Proliferative Diabetic Retinopathy (NPDR) ringan, sedang NPDR, NPDR berat, dan Diabetes Proliferatif Retinopati (PDR) [3].

International Diabetes Federation (IDF) memberikan data dimana Indonesia berada diposisi kelima terbesar pengidap diabetes didunia. Dengan angka yang pengidap penyakit diabetes yang cukup besar di Indonesia. Oleh karena itu Diabetic Retinopathy harus diketahui sejak awal untuk dapat ditanggulangi. Pada umumnya Diabetic Retinopathy dapat dideteksi dengan melihat pembuluh darah kapiler kecil. Diabetic Retinopathy memiliki 2(dua) kelas yaitu non-proliferative Diabetic Retinopathy (NPDR), dan proliferative Diabetic Retinopathy (PDR). Menurut ahli Ophthalmologist Diabetic Retinopathy dibagi lagi menjadi 4 level kondisi:

Mild Non-proliferative, Moderate Non-proliferative, 3) Severe Non-proliferative, dan Proliferative [4].


Permasalahan Diabetic Retinopathy sudah melalui banyak penelitian oleh berbagai ilmuwan dari tahun ke tahun. Contoh penelitian tersebut adalah penelitian yang dilakukan oleh M. Mohsin Butt dan Ghazanfar Latief dengan judul penelitian Multi-channel Convolutions Neural Network (CNN) Based Diabetic Retinopathy Detection from Fundus Images pada tahun 2019 menggunakan model CNN [5], lalu Syamsul Rizal dengan judul penelitian Deep Learning untuk Klasifikasi Diabetic Retinopathy pada tahun 2020 menggunakan model EfficientNet, [4] dan Wejdan L. Alyoubi dengan judul penelitian Diabetic Retinopathy Fundus Image Classification and Lesions Localization System Using Deep Learning pada tahun 2021 menggunakan model CNN512 dan CNN299 [6].

Ketiga penelitian tersebut menggunakan dataset yang berbeda yaitu EyePAC, APTOS 2019 Blindness Detection, dan dataset campuran DDR and Asia Pacific Tele-Ophthalmology Society (APTOS) 2019 Kaggle. Sehingga penelitian mendapatkan hasil yang berbeda, M. Mohsin Butt dan Ghazanfar Latief mendapatkan hasil 88,702 citra yang coba divalidasi menggunakan beberapa model diperoleh hasil terbaik pada Model 2, akurasi maksimum 96,85% diamati untuk Gambar Skala Abu-abu, 94,11% untuk Saluran Merah, 93,95% untuk Saluran Hijau, dan akhirnya Akurasi 97,08% untuk Saluran Biru [5]. Syamsul Rizal mendapatkan hasil 3662 citra berwarna pada klasifikasi 5 kelas diabetes retinopati mendapat akurasi sebesar 75% untuk data asli dan 79.8% melalui proses CLAHE dan menggunakan *optimizer* SGD dengan learning rata yang digunakan sebesar 0.0001 dan momentum 0.9 [4]. Dan Wejdan L. Alyoubi mendapatkan hasil model CNN512 mendapat tingkat akurasi sebesar 0.886 % sedangkan CNN299 gagal dalam mendeteksi proses training [6].

II. KAJIAN TEORI

Convolutional Neural Network (CNN) adalah variasi dari Multilayer Perceptron (MLP) untuk menganalisis data 2(dua) dimensi berupa gambar. Secara umum, CNN merupakan arsitektur yang dapat dilatih yang berisi dari banyak langkah. Setiap input dan output tahap terdiri dari banyak array yang dikenal sebagai feature map. Convolution

layer, lapisan fungsi aktivasi, dan polling layer adalah tiga lapisan yang membentuk setiap tahap. *Convolutional Neural Network* (CNN) merupakan jenis arsitektur yang dirancang untuk memproses data *grid*, seperti gambar atau data spasial. CNN sangat efektif dalam klasifikasi gambar dikarenakan menggunakan operasi matematika yang disebut konvolusi pada setidaknya satu lapisannya untuk menghasilkan fitur-fitur gambar yang lebih tinggi. CNN berisi beberapa lapisan seperti konvolusi, lapisan *pooling*, dan lapisan *fully connected*. Lapisan konvolusi bertanggung jawab mengekstrak fitur-fitur gambar dari input gambar. Lapisan *pooling* juga dapat mengurangi dimensi *output* dari lapisan konvolusi. Lapisan *fully connected* bertanggung jawab untuk menghubungkan *output* dari lapisan sebelumnya ke *output* terakhir.



GAMBAR 1 Arsitektur Covolutional Neural Network

III. METODE

Metode klasifikasi penyakit dilakukan dengan beberapa tahapan dan skenario. Tahapan pertama yaitu pengambilan dataset sekunder campuran dari website Kaggle yang berisi data dari Aravind Eye Hospital di India yang digunakan untuk kompetisi Asia Pasific Tele-Ophthalmology Society (APTOS). Dataset berupa APTOS 2019 Blindness Detection 224x224 [15] dan dataset berasal dari GNU Lesser General Public License [16]. Dengan pembagian data seperti pada tabel dibawah:

TABEL 1 Daftar Pembagian Dataset

Tingkatan	Aptos 2019 Blindness Detection 224x224	GNU Lesser General Public License	Total Gambar
No_DR	1805 Gambar	0 Gambar	1805 Gambar
Mild_DR	370 Gambar	1430 Gambar	1800 Gambar
Moderate_DR	999 Gambar	0 Gambar	999 Gambar
Severe_DR	193 Gambar	780 Gambar	1063 Gambar
Proliferate_DR	295 Gambar	700 Gambar	995 Gambar
Total Gambar			6.662 Gambar

Penggunaan dataset campuran dilakukan dengan pembagian 70% data train sebesar 4.662 gambar, 20% data validation sebesar 1.331 gambar, dan 10% data test sebesar 669 gambar.

Pada skenario pengujian penelitian ini dilakukan dengan beberapa parameter yang berbeda.

Setelah pengambilan dataset dilanjutkan dengan *machine learning* menggunakan model CNN, dikarenakan CNN merupakan jenis yang dirancang memproses data grid untuk suatu gambar. Model CNN yang digunakan merupakan EfficientNetV2s dengan parameter seperti : *Optimizer*, *Learning rate*, *Batch size* dan *Epoch*.

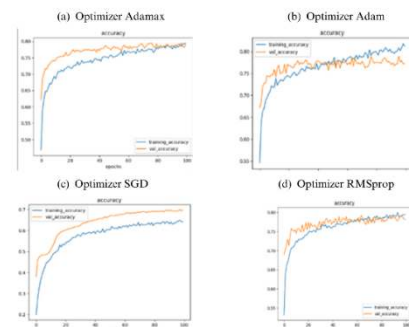
TABEL 2 Layer Pada Sistem Model

Layer	Parameters	Output Shape
Efficientnetv2-s	20331360	(None, 1280)
Dropout	0	(None, 1280)
Dense	163968	(None, 128)
Dropout_1	0	(None, 128)
Dense_1	8256	(None, 64)
Dropout_2	0	(None, 64)
Dense_2	2080	(None, 32)
Dropout_3	0	(None, 32)
Flatten	0	(None, 32)
Dense_3	165	(None, 5)

Pengujian ini menjelaskan hasil dan analisa nilai akurasi berdasarkan skenario pengujian yang telah dirancang. Terdapat empat pengujian yang telah dilakukan, dimana empat skenario tersebut dilakukan untuk mengidentifikasi parameter *optimizer*, *learning rate*, ukuran *batch size*, dan ukuran *epoch* terbaik pada metode CNN. Dari empat skenario tersebut akan ditarik kesimpulan mengenai hasil yang terbaik. Hasil pengujian ini menggunakan setiap hyperparameter yang terbaik dari *optimizer*, *learning rate*, *batch size*, dan *epoch* menggunakan model EfficientNetV2s.

A. Pengujian 1 (*Optimizer*)

Pengujian 1 kami melakukan perubahan pada setiap parameter *optimizer* untuk setiap data yang akan kami latih. *Optimizer* merupakan metode yang dapat mengubah bobot dan *learning rate* sehingga dapat mengurangi loss. Pemilihan jenis *optimizer* ini memberikan tingkat akurasi dan loss yang berbeda yaitu dengan membandingkan setiap parameter *optimizer* Adam, Adamax, SGD, dan RMSprop. Setiap parameter *optimizer* akan di uji menggunakan dataset campuran, model EffecientNetV2s, *learning rate* 0.001, ukuran *epoch* 100, dan *batch size* 32. Hasil terbaik (pengukuran akurasi) dari pengujian 1 akan menjadi parameter untuk pengujian selanjutnya.

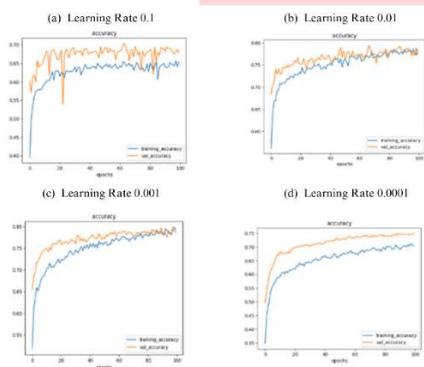


GAMBAR 2

Hasil Pengujian *Optimizer* (a) Adamax (b) Adam (c) SGD (d) RMSprop

B. Pengujian 2 (*Learning rate*)

Pengujian 2 kami melakukan perubahan pada setiap parameter *learning rate* untuk setiap data yang akan kami latih. *Learning rate* sendiri adalah parameter training untuk nilai koreksi bobot di proses training dengan range nol (0) sampai (1). Semakin besar nilai suatu *learning rate*, maka proses training juga semakin cepat berjalannya, namun ketelitian jaringan akan semakin berkurang. Maupun sebaliknya, semakin kecil atau rendah nilai suatu *learning rate*, maka ketelitian jaringan akan semakin bertambah namun proses training akan semakin lama. Untuk mendapatkan model terbaik, kami membandingkan setiap parameter *learning rate* 0.1, 0.01, 0.001, dan 0.0001. Setiap parameter *optimizer* akan di uji menggunakan dataset campuran, model EffecientNetV2s, *optimizer* Adamax, ukuran *epoch* 100, dan *batch size* 32. Hasil terbaik (pengukuran akurasi) dari pengujian 2 akan menjadi parameter untuk pengujian selanjutnya.

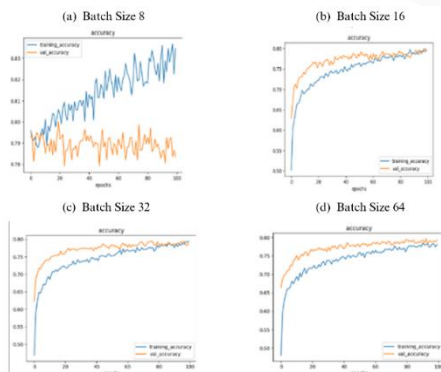


GAMBAR 3

Hasil Pengujian *Learning rate* (a) *Learning rate* 0.1 (b) *Learning rate* 0.01 (c) *Learning rate* 0.001 (d) *Learning rate* 0.0001

C. Pengujian 3 (*Batch size*)

Pada pengujian 3 kami melakukan perubahan pada setiap parameter *batch size* untuk setiap data yang akan kami latih. *Batch size* sendiri merupakan jumlah sampel yang akan diproses dalam 1 iterasi. Kami akan membandingkan setiap ukuran parameter *batch size* 8, 16, 32, dan 64. Setiap parameter optimezer akan di uji menggunakan dataset campuran, model EffecientNetV2s, *optimizer* Adamax, ukuran *epoch* 100, dan *learning rate* 0.001. Hasil terbaik (pengukuran akurasi) dari pengujian 3 akan menjadi parameter untuk pengujian selanjutnya.

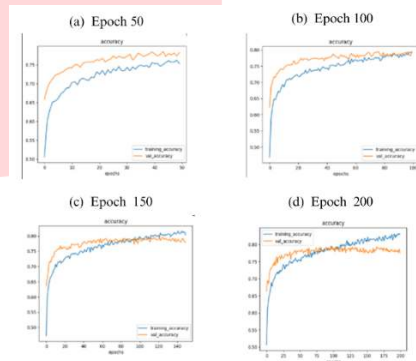


GAMBAR 4

Hasil Pengujian *Batch size* (a) *Batch size* 8 (b) *Batch size* 16 (c) *Batch size* 32 (d) *Batch size* 64

D. Pengujian 4 (*Epoch*)

Pada pengujian 4 kami melakukan perubahan pada setiap parameter *epoch* untuk setiap data yang akan kami latih. *Epoch* adalah proses pelatihan model terdiri dari serangkaian iterasi atau langkah-langkah dalam setiap training model tersebut. Pada setiap *epoch*, data pelatihan diberikan kepada model, kemudian model menghasilkan prediksi. Selanjutnya, prediksi ini dibandingkan dengan nilai yang sebenarnya atau target yang diketahui dari data pelatihan tersebut. Kami membandingkan setiap ukuran parameter *epoch* 50, 100, 150, dan 200. Setiap parameter *optimizer* akan di uji menggunakan dataset campuran, model EffecientNetV2s, *optimizer* Adamax, dan *learning rate* 0.001. Hasil terbaik (pengukuran akurasi) dari pengujian 4 akan menjadi parameter untuk pengujian selanjutnya.



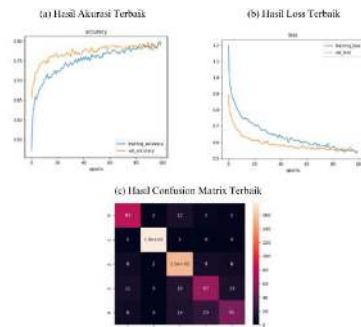
GAMBAR 5

Hasil Pengujian *Epoch* (a) *Epoch* 50(limapoluh) (b) *Epoch* 100 (seratus) (c) *Epoch* 150 (seratu-limapoluh) (d) *Epoch* 200 (duaratus)

IV. HASIL DAN PEMBAHASAN

Hasil keempat pengujian tersebut akan ditarik kesimpulan mengenai hasil yang terbaik Menggunakan setiap hyperparameter yang terbaik dari *optimizer*, *learning rate*, *batch size*, dan *epoch* menggunakan model EffecientNetV2s. Dataset campuran dilatih dengan pembagaian 70% data train sebesar 4.662 gambar, 20% data validation sebesar 1.331 gambar, dan 10% data test sebesar 669 gambar dengan data berupa : No_DR, Mild_DR, Moderate_DR, Severe_DR, Proliferaate_DR menggunakan metode CNN model EffecientNetV2s, *optimizer* Adamax, ukuran *learning rate* 0.001, ukuran *batch size* 32, ukuran *epoch* 100.

Berikut kami lampirkan hasil pengujian terbaik dan performa sistem terbaik yang kami latih pada GAMBAR 6 dan TABEL 3.



GAMBAR 6 Hasil Pengujian Terbaik

TABEL 3
Performa Model Pengujian Terbaik

Tingkatan	Presisi (%)	Recall (%)	F-1 score (%)	Jumlah Gambar
No_DR	78	85	85	82
Mild_DR	74	81	81	177
Moderate_DR	98	98	98	153
Severe_DR	71	55	55	67
Prolifera DR	66	63	63	55
Rata-rata	77	76	76	534/669

Dari hasil pengujian terbaik yang kami dapatkan pada TABEL 4 akurasi sebesar 80%, presisi 77%, recall 76%, f1-score 76%. Dengan hasil akurasi, hasil loss, presisi, recall, f1-score, dan confusion matrix seperti grafik di GAMBAR 6 tersebut. Kami dapat simpulkan tidak overfitting dan pengujian data latih stabil.

TABEL 4
Hasil Pengujian Terbaik

Hasil	Angka
Akurasi	80%
Presisi	77%
Recall	76%
F1-Score	76%

V. KESIMPULAN

Klasifikasi penyakit *Diabetic Retinopathy* dengan metode CNN model EfficientNetV2s melakukan pengujian yang mempunyai 4 (empat) parameter yaitu *optimizer*, *learning rate*, *batch size*, dan *epoch*. *Optimizer* menggunakan *optimizer* Adam, Adamax, SGD, dan RMSProp mendapatkan hasil akurasi terbaik yaitu Adamax sebesar 80%. *Learning rate* menggunakan ukuran 0,1, 0,01, 0,001, dan 0,0001 mendapatkan hasil akurasi terbaik yaitu 0,001 sebesar 80%. *Batch size* menggunakan ukuran 8, 16, 32, dan 64 mendapatkan hasil akurasi terbaik yaitu *Batch size* ukuran 32

sebesar 80%. Dan *Epoch* menggunakan ukuran 50, 100, 150, dan 200 mendapatkan hasil akurasi terbaik yaitu ukuran 100 sebesar 80%. Sehingga hasil pengujian terbaik kami yaitu tidak *overfitting*, akurasi sebesar 80%, presisi sebesar 77%, *recall* sebesar 76%, dan F1-Score sebesar 76%.

REFERENSI

- [1] World Health Organisation (WHO). 2021. Diabetes. Website:<https://www.who.int/newsroom/factsheets/detail/diabetes>. Diakses pada 18 Agustus 2023.
- [2] Wong, Aiello, Ferris, Gupta, Kawasaki, and Lansingh, 2017, "Update 2017 ICO guideline for diabetic eye care", *Ophthalmol*, page 1-33.
- [3] Wilkinson, 2003, "Propose international clinical diabetic retinopathy and diabetic macular edema disease severity scales", volume 110, number 9, p.p 1677-1682.
- [4] S. Rizal, N.Ibrahim, N. K. C. Pratiwi, S. Saidah, and R. Y. N. Fu'adah, 2020, "Deep Learning untuk klasifikasi Diabetic Retinopathy menggunakan model EfficientNet", *ELKOMIKA J. T.Energi Elektr. T. Telekomun. T.Elektron.*, vol. 8, no. 3, p. 693, doi: 10.26760/elkomika.v8i3.693.
- [5] Butt, G. Latif, Iskandar, Alghazo, and Khan, 2019, "Multi-channel Convolutions Neural Network Based Diabetic Retinopathy Detection from Fundus Images," *Procedia Comput. Sci.*, volume. 163, p.p. 283– 291, doi: 10.1016/j.procs.2019.12.110.
- [6] Alyoubi, Abulkhair, and Shalash, 2021, "Diabetic Retinopathy Fundus Image Classification and Lesion Localization System using Deep Learning," *Sensors*, volume 21, number 11, p.p 1–22, doi: 10.3390/s21113704.
- [7] S.R Rath. 2021. Diabetic Retinopathy 224x224. Tersedia di: <https://www.kaggle.com/datasets/sovitrath/diabetic-retinopathy-224x224-2019>, datadiakses pada tanggal 15 November 2022
- [8] S.Kumar. 2022. Diabetic Retinopathy Preprocessed Dataset, Tersedia di: <https://www.kaggle.com/datasets/sachinkumar413/diabetic-retinopathy-preprocessed-dataset>, diakses pada tanggal 15 November 2022