



# Klasifikasi Tingkat Keparahan Penyakit Diabetic Retinopathy menggunakan Convolutional Neural Network

Ni Luh Wiwik Sri Rahayu Ginantra\*, Theresia Hendrawati, I Kadek Diksa Bayu Prasetya

Teknologi dan Informatika, Informatika, Institut Bisnis dan Teknologi Indonesia, Denpasar  
Jl. Tukad Pakerisan No.97, Panjer, Denpasar Selatan, Kota Denpasar, Bali, Indonesia  
Email: <sup>1,\*</sup>wiwik@instiki.ac.id, <sup>2</sup>theresia.hendrawati2@instiki.ac.id, <sup>3</sup>bayuprasetya24@gmail.com  
Email Penulis Korespondensi: wiwik@instiki.ac.id

Submitted: 24/05/2025; Accepted: 23/07/2025; Published: 31/07/2025

**Abstrak**—Diabetic Retinopathy merupakan kondisi mata pada penderita Diabetes yang menyebabkan kerusakan pada retina, yang dapat mengakibatkan kebutaan permanen jika tidak diobati dengan baik. Tahap awal penyakit ini ialah terjadinya pelebaran pembuluh darah di mata yang jika tidak ditangani, dapat menyebabkan pembentukan pembuluh darah baru yang dapat menutupi retina mata, sehingga meningkatkan resiko kehilangan penglihatan. Terdapat beberapa kelas dalam penyakit Diabetic Retinopathy, dalam menentukan kelas dapat menggunakan metode Deep Learning yang dapat memodelkan berbagai data seperti gambar. Proses klasifikasi dilakukan dengan melatih model Convolutional Neural Network (CNN) pada dataset citra penyakit yang diambil dari repository Kaggle dengan jumlah 5 kelas. Penelitian ini menggunakan strategi Fine Tuning dan model EfficientNetB1 untuk mengetahui kinerja model CNN dalam proses Klasifikasi Diabetic Retinopathy. Berdasarkan hasil pelatihan, model EfficientNetB1 menghasilkan akurasi 92.51% dalam mendeteksi Diabetic Retinopathy. Hasil tersebut menunjukkan bahwa model mampu memberikan hasil yang optimal dalam proses pelatihan dataset.

**Kata Kunci:** Diabetic Retinopathy; Deep Learning; Convolutional Neural Network (CNN); EfficientNetB1; Fine Tuning

**Abstract**—Diabetic Retinopathy is an eye condition in Diabetes sufferers that causes damage to the retina, which can result in permanent blindness if not treated properly. The initial stage of this disease is the widening of the blood vessels in the eye which, if left untreated, can cause the formation of new blood vessels which can cover the retina of the eye, thereby increasing the risk of vision loss. There are several classes of Diabetic Retinopathy disease; to determine the class you can use the Deep Learning method which can model various data such as images. The classification process is carried out by training a Convolutional Neural Network model on a disease image dataset taken from the Kaggle repository with a total of 5 classes. This research uses a Fine Tuning strategy and the EfficientNetB1 model to determine the performance of the CNN model in the Diabetic Retinopathy Classification process. Based on training results, the EfficientNetB1 model produces 92.51% accuracy in detecting Diabetic Retinopathy. These results show that the model can provide optimal results in the dataset training process.

**Keywords:** Diabetic Retinopathy; Deep Learning; Convolutional Neural Network (CNN); EfficientNetB1; Fine Tuning

## 1. PENDAHULUAN

Pada tahun 2019 World Health Organization (WHO) menyatakan bahwa Diabetes menempati urutan ke sembilan penyakit yang menyebabkan kematian di dunia. Sejak tahun 2000, Diabetes mengalami peningkatan persentase yang sangat signifikan sebesar 70%. Diabetes merupakan penyakit yang disebabkan oleh kadar glukosa dalam darah yang terlalu tinggi. Apabila dalam jangka waktu yang cukup lama penyakit ini dibiarkan, maka dapat menyebabkan berbagai macam penyakit yang berkelanjutan seperti gagal ginjal, luka pada kaki, gangguan penglihatan, dan gangguan pada saraf. Berbagai komplikasi dapat timbul akibat Diabetes yang dapat merusak sistem tubuh, salah satunya yaitu Diabetic Retinopathy yang selanjutnya disingkat DR [1].

Diabetic Retinopathy (DR) adalah penyakit mata akibat kerusakan retina yang bisa menyebabkan kebutaan permanen jika tidak diobati lebih lanjut. Pada tahap awal, terjadi pelebaran pembuluh darah mata yang jika tidak segera diatasi dapat memicu pembentukan pembuluh baru yang menutupi retina dan berpotensi menyebabkan kehilangan penglihatan. Berdasarkan tingkat keparahannya, menurut ahli ophthalmologist, DR diklasifikasikan ke dalam empat level: Mild Non-proliferative, Moderate Non-proliferative, Severe Non-proliferative, dan Proliferative [2]. Diagnosa dini sangat penting untuk memberikan penanganan tepat dan mencegah kerusakan lebih parah. Diagnosa otomatis dapat membantu dokter mempercepat tahap awal dengan memanfaatkan citra retina dari funduskopi menggunakan ophthalmoscope, alat untuk menerangi dan memperbesar gambaran dalam mata penderita DR. Funduskopi adalah pemeriksaan fundus mata untuk menilai secara langsung segmen posterior mata sehingga menghasilkan citra fundus retina yang detail dan akurat [3]. Teknik ini sangat membantu dalam deteksi dan monitoring perkembangan penyakit.

Deep learning (DL) merupakan subdomain dalam machine learning yang melibatkan hierarkis tahap pemrosesan non-linier untuk menghasilkan pembelajaran fitur, dan machine learning ini digunakan untuk mengklasifikasikan pola dengan tingkat akurasi tinggi [4]. DL menjadi salah satu metode diagnosis medis yang berbantuan komputer yang sangat efektif. Dengan kemampuannya untuk menganalisis data medis skala besar, DL juga dapat membantu di dunia medis untuk mengidentifikasi penyakit [5], menginterpretasi gambar medis tentang penyakit yang diderita oleh pasien [6], serta memberikan rekomendasi perawatan yang lebih akurat dan tepat terhadap pasien yang terdeteksi penyakit [7]. Terdapat berbagai aspek dalam penerapan DL seperti klasifikasi, segmentasi, deteksi, pengambilan, dan registrasi citra. Klasifikasi digunakan untuk mengidentifikasi jenis penyakit atau kondisi tertentu pada citra medis.

Convolutional Neural Network (CNN) merupakan varian jaringan saraf tiruan yang dirancang untuk mengenali pola pada data visual seperti gambar. CNN memiliki berbagai bobot atau parameter untuk mengekstraksi fitur dari data visual. Berbeda dari jaringan saraf biasa, CNN memiliki arsitektur yang dioptimalkan untuk menangani data spasial seperti gambar [8]. CNN terdiri dari dua bagian, yaitu feature extraction yang mencakup convolutional layer, pooling layer, dan aktivasi ReLU, serta classification layer yang mencakup fully connected layer, fungsi flatten, dan fungsi aktivasi [9]. Dalam klasifikasi ini digunakan EfficientNetB1 sebagai model dasar yang telah dilatih sebelumnya. EfficientNetB1 adalah CNN yang efisien, menggunakan depthwise separable convolution dan teknik lanjutan lainnya untuk mencapai akurasi tinggi dengan jumlah parameter lebih sedikit [10]. Model ini melewati lapisan GlobalAveragePooling2D, diikuti dua lapisan padat dan fungsi aktivasi softmax untuk menghasilkan probabilitas kelas yang akurat. Dengan demikian, model ini dirancang untuk menghasilkan klasifikasi optimal dengan efisiensi parameter yang tinggi [11].

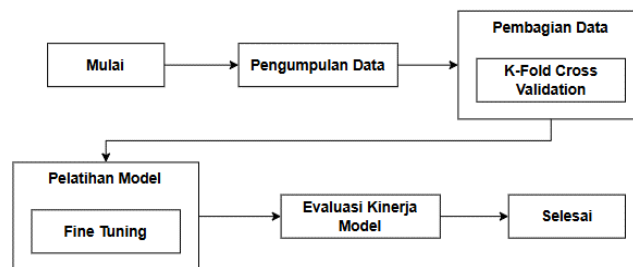
Penelitian terdahulu mengusulkan pendekatan CNN dalam klasifikasi Diabetic Retinopathy. [12] mengusulkan pendekatan ensemble deep learning menggunakan berbagai arsitektur CNN (ResNet-50, InceptionV3, Xception, Dense121, Dense169) untuk klasifikasi tahapan Diabetic Retinopathy (DR). Model ini mampu mendeteksi seluruh tahapan DR dan menunjukkan kinerja lebih baik dibandingkan metode lain, meskipun akurasi yang dicapai hanya 58,08%. Selanjutnya [13] mengembangkan pendekatan berbasis integrated shallow CNN multi-skala. Hasilnya menunjukkan peningkatan akurasi klasifikasi sebesar 3–9% dibandingkan metode CNN tradisional, terutama efektif pada dataset kecil. [14] menggunakan model EfficientNet untuk klasifikasi lima level DR dengan akurasi 79,8%, specificity 93,11%, dan sensitivity 80%. Model ini menggunakan optimizer SGD dan menunjukkan performa yang baik. Kemudian [15] menggabungkan ResNet-50 dan DenseNet-121 dalam kerangka boosting ensemble untuk klasifikasi keparahan DR menjadi 4 kelas, hasil akurasi mencapai 95,58%. Dan [16] memanfaatkan CNN berbasis EfficientNet untuk klasifikasi DR pada dataset APTOS 2019. Model terbaik menggunakan optimizer Adamax dengan akurasi 82,10%, presisi 67,6%, recall 63,4%, dan F1-score 64,6%.

Berdasarkan pemaparan di atas, penelitian ini mengusulkan penerapan CNN untuk membangun model klasifikasi yang memanfaatkan data citra retina guna diagnosa tingkat keparahan penyakit Diabetic Retinopathy. Model klasifikasi ini diharapkan dapat menghasilkan kinerja klasifikasi yang tinggi yang dapat mendiagnosa penyakit Diabetic Retinopathy berdasarkan data citra yang diamati.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian


Penelitian ini mengusulkan model klasifikasi EfficientNetB1 dengan augmentasi data dan fine tuning. Proses meliputi pengumpulan dataset, pembagian data K-Fold Cross Validation, pelatihan, fine tuning, dan evaluasi. Alur pengembangan model klasifikasi penyakit Diabetic Retinopathy ditampilkan pada Gambar 1.



**Gambar 1.** Tahapan Model Klasifikasi Penyakit Diabetic Retinopathy

#### 2.1.1 Pengumpulan Data

Pada penelitian ini digunakan dataset citra retina yang terdiri dari 3.662 gambar, mencakup penderita dan non-penderita Diabetic Retinopathy. Dataset dibagi ke dalam 5 kelas: 1.805 citra No\_DR, 370 mild, 999 moderate, 193 severe, dan 295 proliferate\_DR. Ukuran citra yang digunakan adalah 224x224 piksel. Contoh citra dari masing-masing kelas dapat dilihat pada Gambar 2.



**Gambar 2.** Sampel Dataset Citra Penyakit Diabetic Retinopathy Dan Citra Tidak Terhidap Diabetic Retinopathy (A) No\_DR, (B) Mild, (C) Moderate, (D) Severe, (E) Proliferate\_DR



### 2.1.2 Pembagian Data (K-Fold Cross Validation)

Dataset dibagi menjadi 80% data latih dan 20% data uji. Untuk meningkatkan akurasi dan mencegah overfitting, digunakan five-fold cross validation yang membagi data latih menjadi lima fold sama besar. Empat fold dipakai untuk pelatihan dan satu untuk validasi secara bergantian selama lima iterasi. Teknik ini menghasilkan evaluasi model yang lebih stabil dan kinerja lebih andal. Ilustrasi proses ditunjukkan pada Gambar 3.

### 2.1.3 Pelatihan Model (Fine Tuning)

Model klasifikasi pada penelitian ini dibangun menggunakan arsitektur EfficientNetB1, yang dipilih karena memiliki efisiensi tinggi dengan jumlah parameter relatif kecil, sekitar 7,9 juta. Pengembangan dilakukan menggunakan Google Colab dan Visual Studio Code, dengan memanfaatkan GPU NVIDIA Tesla T4 dan dukungan framework TensorFlow serta library Keras.

### 2.1.4 EfficientNetB1

EfficientNetB1 merupakan varian dari arsitektur EfficientNet yang dikembangkan oleh Google Brain (2019), dengan keseimbangan antara ukuran dan kinerja [17]. Arsitektur ini menggabungkan scaling dalam hal kedalaman, lebar, dan resolusi citra untuk meningkatkan performa klasifikasi. Varian B1 memiliki ukuran yang lebih kecil dibandingkan versi lainnya seperti B2 atau B3.

### 2.1.5 Fine Tuning

Fine tuning dilakukan pada model pre-trained EfficientNetB1 untuk meningkatkan performa klasifikasi terhadap citra Diabetic Retinopathy. Fine tuning mencakup penyesuaian hyperparameter penting seperti learning rate dan optimizer [18]. Learning rate mengontrol seberapa besar bobot diperbarui selama pelatihan, sedangkan optimizer seperti Adam digunakan untuk meminimalkan nilai loss. Penyesuaian ini dilakukan secara spesifik untuk memperoleh kombinasi parameter terbaik, seperti yang ditampilkan pada Tabel 1.

**Tabel 1.** Penyesuaian Variasi Hyperparameter Dalam Strategi Fine Tuning Pada Pelatihan Model Klasifikasi

Model	Strategi Fine Tuning	
	Learning Rate	Optimizers
EfficientNetB1	0,0001	Adam

### 2.1.6 Evaluasi Kinerja Model

Kinerja model klasifikasi ini diukur dan dievaluasi menggunakan metrik Recall, Precision, F1-score, dan Accuracy [19]. Evaluasi ini bertujuan mengukur performa model setelah penerapan strategi fine tuning dengan berbagai kombinasi hyperparameter, seperti nilai dropout dan jenis optimizer. Hasil perubahan kinerja berdasarkan variasi tersebut disajikan pada Tabel 2.

**Tabel 2.** Skenario Evaluasi Kinerja Model Dengan Kombinasi Hyperparameter dalam Strategi FTine Tuning Pada Model Klasifikasi

Model	Fine Tuning		Field			
	Learning Rate	Optimizer	Recall	Precision	F1-Score	Accuracy
EfficientNetB1						









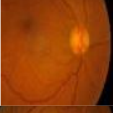


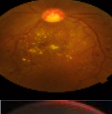
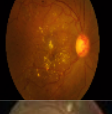


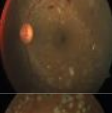
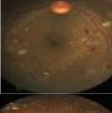
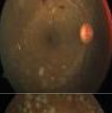





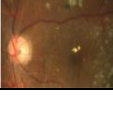

## 3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan mendeteksi penyakit Diabetic Retinopathy menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur EfficientNetB1. Bab ini membahas tahapan implementasi sistem, mulai dari pra-pemrosesan data, pelatihan model, hingga evaluasi kinerja menggunakan confusion matrix dan metrik seperti akurasi, presisi, recall, dan F1-score untuk mengukur kemampuan klasifikasi model.

### 3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan data sekunder yang tersedia secara publik melalui situs Kaggle: <https://www.kaggle.com/datasets/sovitrath/diabetic-retinopathy-224x224-2019-data>. Dataset tersebut berisi 3.662 citra mata penderita dan non-penderita Diabetic Retinopathy, yang terbagi ke dalam lima kelas, yaitu No\_DR (1.805 citra), mild (370 citra), moderate (999 citra), severe (193 citra), dan proliferate\_DR (295 citra). Seluruh citra telah diubah ukurannya menjadi 224x224 piksel agar sesuai dengan kebutuhan pemrosesan model. Untuk menyeimbangkan jumlah data di tiap kelas serta meningkatkan keragaman, dilakukan augmentasi menggunakan PyTorch transforms, yang meliputi resize, rotasi acak hingga 30°, flip horizontal, translasi, dan skala acak. Setelah augmentasi, citra dikonversi ke format tensor. Hasil augmentasi ditampilkan pada Tabel 3.

**Tabel 3.** Metode Modifikasi Dalam Setiap Kelas

Kelas	Gambar	Rotasi	Flip	Zoom	Translasi
No_DR					
Mild					
Moderate					
Severe					
Prolife-rate DR					

### 3.2 Pembagian Data

Dataset yang digunakan dalam proses klasifikasi ini dibagi ke dalam dua kategori, yaitu data latih (training) dan data uji (testing), dengan pembagian proporsi sebesar 80% atau 2.929 citra untuk data training dan 20% atau 733 citra untuk data testing. Dengan demikian, total 3.662 citra terbagi secara proporsional agar model dapat belajar dengan baik dan dievaluasi secara optimal.

### 3.3 Metode Convolutional Neural Network (CNN)

Dalam penelitian ini, CNN digunakan untuk memproses citra retina dari pasien dan mengklasifikasikan tingkat keparahan Diabetic Retinopathy. Proses klasifikasi ini dilakukan secara bertahap melalui tahapan berikut:

#### 3.3.1 Input

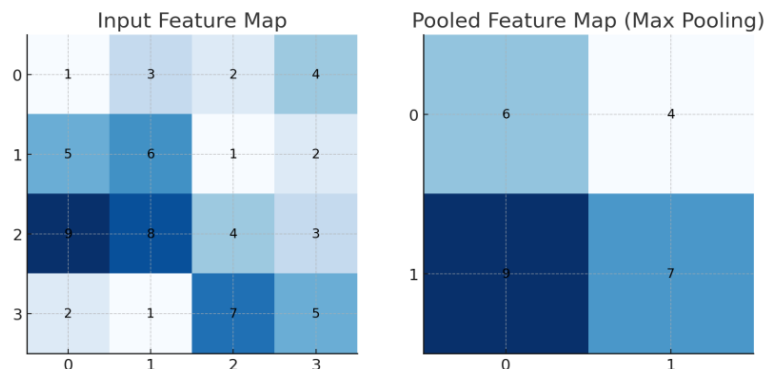
Tahapan ini merupakan masukan awal berupa citra retina dari dataset Diabetic Retinopathy, baik yang mengandung indikasi penyakit maupun yang normal. Gambar ini digunakan sebagai sampel untuk dilatih dalam jaringan CNN guna mendeteksi dan mengklasifikasikan fitur yang relevan.

#### 3.3.2 Convolutional Layer

Citra akan diproses melalui lapisan konvolusional, di mana sejumlah filter digunakan untuk mengekstraksi fitur penting seperti tepi dan pola visual [20]. Digunakan batch size sebesar 32 untuk meningkatkan efisiensi pelatihan dan stabilitas estimasi gradien selama proses pelatihan [21].

#### 3.3.3 Pooling Layer

Setelah melalui lapisan konvolusional, fitur map akan dikurangi dimensinya menggunakan max pooling. Proses ini membantu mempertahankan informasi paling penting, mengurangi jumlah parameter, serta mencegah overfitting [20], sehingga pelatihan menjadi lebih efisien. Ilustrasi Max Pooling dapat dilihat pada Gambar 3.



**Gambar 3.** Ilustrasi Max Pooling dalam Pooling Layer

### 3.3.4 Fully Connected Layer

Lapisan ini menghubungkan semua neuron dari lapisan sebelumnya untuk membentuk pemetaan akhir. Output layer akan menghasilkan prediksi kelas berdasarkan hasil ekstraksi fitur sebelumnya, berupa probabilitas dari masing-masing kelas penyakit yang diprediksi [20].

### 3.4 Pembangunan Model

Pembangunan model CNN berperan penting dalam klasifikasi citra, mencakup ekstraksi fitur, klasifikasi, generalisasi, optimasi, dan evaluasi kinerja [22]. Penelitian ini menggunakan arsitektur EfficientNetB1 sebagai model utama, yang dirancang untuk memberikan performa tinggi dengan efisiensi komputasi. Dengan teknik compound scaling, EfficientNetB1 menyeimbangkan kedalaman, lebar, dan resolusi gambar untuk meningkatkan akurasi tanpa memperbesar ukuran model. Arsitektur ini efisien dalam mengekstraksi fitur penting dari citra retina, serta hemat memori dan waktu pelatihan dibandingkan model konvensional.

### 3.5 Fine Tuning

Strategi fine tuning dalam penelitian ini melibatkan penyesuaian learning rate untuk mengontrol perubahan parameter, menggunakan optimizer bertujuan untuk meminimalkan fungsi kerugian (loss), dan penerapan dropout sebagai pengendali untuk mencegah overfitting [17]. Parameter Fine Tuning dilihat pada Tabel 4.

**Tabel 4.** Parameter Fine Tuning

Parameter	Learning Rate	Optimizer	Dropout
Nilai	0.0001	Adam	0.5

#### 3.5.1 Learning Rate

Learning rate sebesar 0,0001 digunakan untuk memastikan pembaruan parameter model berjalan perlahan dan stabil, menghindari overshooting [23]. Meskipun memerlukan waktu pelatihan lebih lama, nilai ini meningkatkan stabilitas, akurasi, dan kemampuan generalisasi model terhadap data baru.

#### 3.5.2 Optimizer

Penelitian ini menggunakan optimizer Adam karena kemampuannya menyesuaikan learning rate secara adaptif dengan memanfaatkan momentum dan rata-rata kuadrat gradien [23]. Adam mempercepat pelatihan, meningkatkan stabilitas, dan membantu model mencapai kinerja optimal dengan risiko overfitting lebih rendah.

#### 3.5.3 Dropout

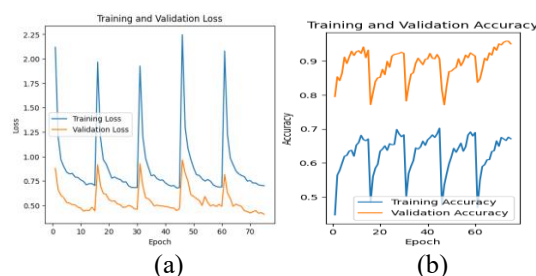
Penelitian ini menggunakan dropout 0,5 untuk mencegah overfitting dan meningkatkan generalisasi dengan mengabaikan secara acak 50% unit jaringan saat pelatihan [20]. Teknik ini membantu model belajar representasi lebih kuat dan stabil pada data baru.

### 3.6 Pelatihan Model

Model dilatih menggunakan k-Fold Cross Validation selama 75 epoch per fold dengan EfficientNetB1, Cross Entropy Loss, dan optimizer Adam. Data dibagi menggunakan Subset Random Sampler, dan akurasi serta loss dipantau tiap epoch. Setelah pelatihan, model dievaluasi dengan data validasi untuk menghitung akurasi, presisi, recall, dan F1-score. Hasil tiap fold, termasuk confusion matrix dan model terlatih, disimpan untuk memastikan evaluasi yang akurat dan menyeluruh.

#### 3.6.1 Hasil Pelatihan Model EfficientNetB1

Model dilatih dengan learning rate 0,0001 selama 15 epoch per fold, menunjukkan penurunan signifikan pada Train dan Validation Loss, serta peningkatan akurasi. Pada Fold 1, Train Loss turun dari 2.1180 ke 0.7031 dan akurasi naik dari 0.7954 ke 0.9319. Tren serupa terjadi pada fold lainnya, menandakan model mampu belajar dan menggeneralisasi dengan baik. Secara keseluruhan, EfficientNetB1 berhasil meningkatkan akurasi, precision, recall, dan F1-score secara stabil. Grafik kinerja ditampilkan pada Gambar 4.



**Gambar 4.** Model Loss (a) dan Model Akurasi (b)

Gambar 4 menampilkan grafik Training dan Validation Loss (a) serta Accuracy (b). Grafik (a) menunjukkan penurunan konsisten pada kedua loss, menandakan berkurangnya kesalahan prediksi. Grafik (b) memperlihatkan peningkatan akurasi pada data pelatihan dan validasi, mencerminkan peningkatan kemampuan klasifikasi model. Secara keseluruhan, EfficientNetB1 berhasil meningkatkan akurasi, precision, recall, dan F1-score secara stabil selama pelatihan.

**3.6.2 Tabel Pelatihan Model EfficientNetB1**

Hasil pelatihan model EfficientNetB1 berdasarkan performa terbaik pada setiap fold. Dari hasil percobaan, model ini menunjukkan akurasi pelatihan tertinggi dengan learning rate 0,0001, yaitu sebesar 0,9583. Hasil ini menunjukkan bahwa EfficientNetB1 mampu belajar secara efektif dan konsisten dalam setiap fold. Hasil pelatihan dapat dilihat pada Tabel 5.

**Tabel 5.** Hasil Pelatihan Menggunakan Model EfficientNetB1 dan Strategi Fine Tuning

Learning Rate	Fold	Train Loss	Val Loss	Accuracy	Precision	Recall	F1-Score
0.0001	1	5,011806	3,091667	6,536806	6,435417	6,536806	6,461111
0.0001	2	4,732639	3,223611	6,427778	6,404167	6,427778	6,365972
0.0001	3	4,922222	3,357639	6,404167	6,3625	6,404167	6,355556
0.0001	4	4,811111	3,384722	6,415278	6,322222	6,415278	6,352083
0.0001	5	4,922222	2,908333	<b>6,654861</b>	6,647917	6,654861	6,641667

**3.7 Evaluasi Kinerja Model**

Setelah pelatihan, model EfficientNetB1 dievaluasi menggunakan metrik akurasi, precision, recall, dan F1-score dengan pendekatan rata-rata tertimbang dari library scikit-learn. Evaluasi dilakukan dengan membandingkan prediksi model pada data validasi atau uji dengan label asli, memberikan gambaran menyeluruh tentang kemampuan dan keandalan model dalam klasifikasi citra.

**3.7.1 Hasil Evaluasi Model**


Hasil evaluasi menunjukkan pelatihan model EfficientNetB1 pada setiap fold memberikan performa yang tinggi dan konsisten. Rata-rata recall yang dicapai sebesar 0,9251 (92,51%), menunjukkan kemampuan model dalam mendeteksi sebagian besar kasus Diabetic Retinopathy secara positif. Precision model sebesar 0,9166 (91,66%) mengindikasikan bahwa mayoritas prediksi positif yang diberikan model adalah benar. Nilai F1-score sebesar 0,9161 (91,61%) mencerminkan keseimbangan antara deteksi dan klasifikasi kasus positif secara tepat. Sedangkan akurasi rata-rata sebesar 0,9251 (92,51%) menegaskan kemampuan model dalam mengklasifikasikan data secara akurat. Setiap fold menunjukkan performa terbaik pada epoch yang berbeda-beda selama proses pelatihan.

Setiap fold mencapai akurasi tertinggi pada epoch berbeda: Fold 1 sebesar 0.9413 (epoch 13), Fold 2 sebesar 0.9256 (epoch 14), Fold 3 sebesar 0.9222 (epoch 11), Fold 4 sebesar 0.9238 (epoch 13), dan Fold 5 sebesar 0.9583 (epoch 13 dan 14). Hasil ini menunjukkan kinerja model yang optimal dan stabil selama proses pelatihan.

**3.7.2 Confusion Matrix EfficientNetB1**

Berikut merupakan tahap evaluasi kinerja model klasifikasi menggunakan arsitektur EfficientNetB1, yang dilakukan untuk mengukur seberapa baik performa model dalam mengklasifikasikan citra menggunakan metrik Recall, Precision, Accuracy, dan F1-Score. Evaluasi ini didasarkan pada model EfficientNetB1 dengan kinerja terbaik dari setiap proses pelatihan.

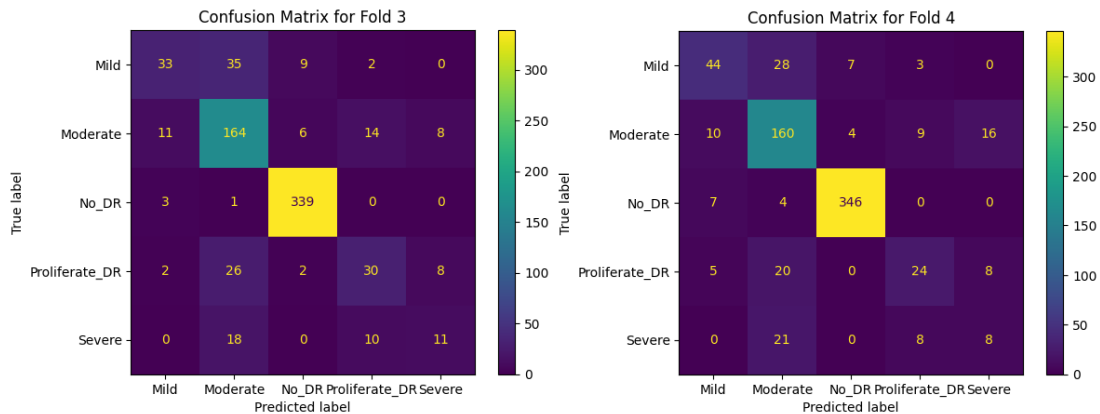
- a. Gambar 5 merupakan confusion matrix pada fold 1. Menunjukkan akurasi benar kelas Mild 43 citra, kelas Moderate 160 citra, kelas No\_Dr 349 citra, kelas Proliferate\_DR 29 citra, dan kelas Severe 13 citra.
- b. Gambar 5 merupakan confusion matrix pada fold 2. Menunjukkan akurasi benar kelas Mild 28 citra, kelas Moderate 163 citra, kelas No\_Dr 360 citra, kelas Proliferate\_DR 28 citra, dan kelas Severe 9 citra.



**Gambar 5.** Confusion Matrix Fold 1 & Confusion Matrix Fold 2

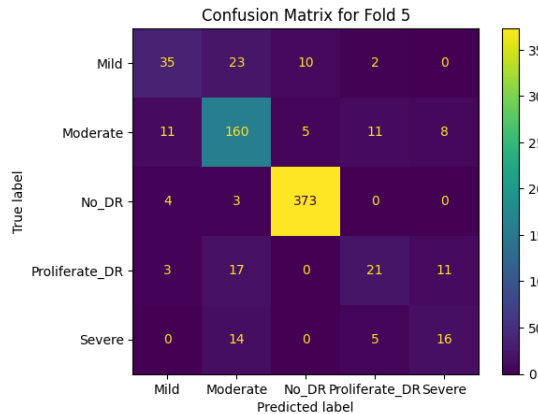
- c. Gambar 6 merupakan confusion matrix pada fold 3. Menunjukkan akurasi benar kelas Mild 33 citra, kelas Moderate 164 citra, kelas No\_Dr 339 citra, kelas Proliferate\_DR 30 citra, dan kelas Severe 11 citra.

- d. Gambar 6 merupakan confusion matrix pada fold 4. Menunjukkan akurasi benar kelas Mild 44 citra, kelas Moderate 160 citra, kelas No\_Dr 346 citra, kelas Prolifera<sub>te</sub>\_DR 24 citra, dan kelas Severe 8 citra.



**Gambar 6.** Confusion Matrix Fold 3 & Confusion Matrix Fold 4

- e. Gambar 7 merupakan confusion matrix pada fold 5. Menunjukkan akurasi benar kelas Mild 35 citra, kelas Moderate 160 citra, kelas No\_Dr 373 citra, kelas Prolifera<sub>te</sub>\_DR 21 citra, dan kelas Severe 16 citra.



**Gambar 7.** Confusion Matrix Fold 5

### 3.8 Pengujian Model

Pada tahap ini dilakukan pengujian terhadap model klasifikasi yang telah dilatih sebelumnya. Pengujian bertujuan untuk mengevaluasi sejauh mana model dapat mengklasifikasikan citra fundus mata ke dalam lima kelas tingkat keparahan Diabetic Retinopathy secara akurat.

#### 3.8.1 Hasil Uji Dataset

Hasil evaluasi menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan data. Dari pengujian yang dilakukan, model mencapai tingkat akurasi sebesar 89,09%, yang mencerminkan seberapa tepat model dalam mengklasifikasikan data. Selain itu, nilai precision yang diperoleh sebesar 88,83% menunjukkan kemampuan model dalam mengidentifikasi kelas positif dengan benar, sementara recall yang mencapai 89,09% mengindikasikan kemampuan model dalam menemukan semua contoh positif yang relevan. Selanjutnya, nilai F1-Score sebesar 88,65% mencerminkan keseimbangan antara precision dan recall, yang menunjukkan bahwa model ini memiliki performa yang baik dalam hal ketepatan dan kelengkapan dalam pengklasifikasian data. Hasil Uji Dataset dapat dilihat pada Gambar 8.

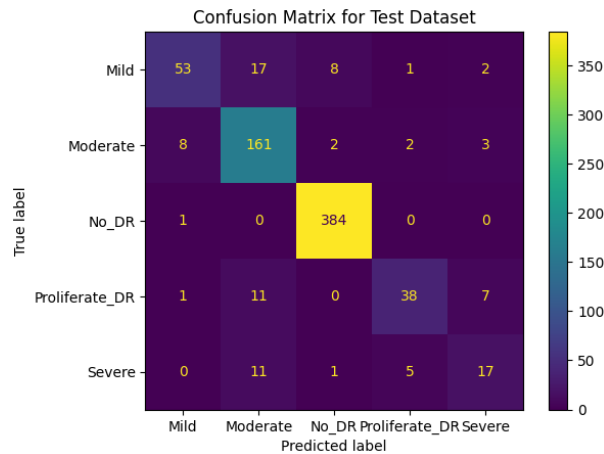
```
Test Accuracy: 0.8909
Test Precision: 0.8883
Test Recall: 0.8909
Test F1 Score: 0.8865
```

**Gambar 8.** Hasil Uji Dataset

#### 3.8.1 Confusion Matrix

Hasil evaluasi menggunakan confusion matrix menunjukkan bahwa model mampu mengklasifikasikan data uji dengan cukup baik dan konsisten. Jumlah citra yang berhasil diklasifikasikan dengan benar pada masing-masing kelas adalah sebagai berikut: kelas Mild sebanyak 53 citra, Moderate sebanyak 161 citra, No\_DR sebanyak 384

citra, Prolifere DR sebanyak 38 citra, dan Severe sebanyak 17 citra. Angka-angka ini menggambarkan kemampuan model dalam mengenali dan membedakan tiap kelas dengan akurasi yang memadai, sehingga mendukung efektivitas model dalam klasifikasi penyakit Diabetic Retinopathy. Hasil evaluasi confusion matrix dapat dilihat pada Gambar 9.



**Gambar 9.** Hasil evaluasi confusion matrix

#### 4. KESIMPULAN

Penelitian ini bertujuan mendeteksi penyakit Diabetic Retinopathy menggunakan metode Convolutional Neural Network (CNN) dengan model EfficientNetB1 sebagai arsitektur utama. Dataset yang digunakan berasal dari Kaggle dan di-input ke dalam penyimpanan repository untuk proses pelatihan. Pelatihan dilakukan dengan learning rate 0,0001 selama 75 epoch yang dibagi dalam beberapa fold. Hasil pengujian menunjukkan bahwa model EfficientNetB1 mampu mencapai akurasi sebesar 92,51%. Ini menandakan kemampuan klasifikasi yang tinggi, dimana model dapat membedakan dengan baik antara retina pasien yang mengalami Diabetic Retinopathy dan retina normal. Dengan demikian, model ini memiliki peluang keberhasilan 92,51% dalam mendeteksi kondisi retina yang benar saat uji diagnosa. Penelitian ini memiliki keterbatasan karena hanya menggunakan satu model CNN, yaitu EfficientNetB1, dan implementasinya terbatas pada sistem berbasis komputer. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan hasil ini sebagai referensi terutama bagi yang mengangkat tema klasifikasi penyakit berbasis citra retina dengan CNN. Pengembangan juga dapat dilakukan dengan mencoba arsitektur CNN lain seperti MobileNetV2, VGG19, atau ResNet101 untuk meningkatkan akurasi.

#### REFERENCES

- [1] E. Sudarmo Dahad Prihanto, M. Sultan Firman Syah, and A. W. Johan Imbar, "Hubungan Pengendalian Diabetes Melitus Type 2 Dengan Kejadian Retinopati Diabetes Di Rsud Dr Chasan Boesoirie Ternate," *Jurnal Health Sains*, vol. 3, no. 12, p. 3, 2022
- [2] M. Vijayan and V. S., "A Regression-Based Approach to Diabetic Retinopathy Diagnosis Using Efficientnet," *Diagnostics*, vol. 13, no. 4, Feb. 2023, doi: 10.3390/diagnostics13040774.
- [3] G. Quellec, H. Al Hajj, M. Lamard, P.-H. Conze, P. Massin, and B. Cochener, "ExplAIn: Explanatory Artificial Intelligence for Diabetic Retinopathy Diagnosis," 2021
- [4] A. Satria Wiratama, M. Rifqi, S. Maesaroh, "Efektivitas Transfer Learning Dalam Pendeteksian Penyakit Pneumonia Melalui Citra X-Ray Paru Manusia." *Repositori Universitas Mercu Buana*, 2023
- [5] J. Civit-Masot, A. Bañuls-Beaterio, M. Domínguez-Morales, M. Rivas-Pérez, L. Muñoz-Saavedra, and J. M. Rodríguez Corral, "Non-small cell lung cancer diagnosis aid with histopathological images using Explainable Deep Learning techniques," *Comput Methods Programs Biomed*, vol. 226, Nov. 2022, doi: 10.1016/j.cmpb.2022.107108.
- [6] L. Zhou et al., "Transfer learning-based DCE-MRI method for identifying differentiation between benign and malignant breast tumors," *IEEE Access*, vol. 8, pp. 17527–17534, 2020, doi: 10.1109/ACCESS.2020.2967820.
- [7] A. , Y. F. , dkk. Demir, "Early detection of skin cancer using deep learning architectures: Resnet-101 and inception-v3," 2019.
- [8] J. S. Sibarani, S. Tumpal Damanik, R. Nurkhalizah, S. Mulyana, and B. Nasution, "Klasifikasi Tanaman Hias Menggunakan Algoritma Convolution Neural Network," 2023.
- [9] M. E. ABDULFATTAH, L. NOVAMIZANTI, and S. RIZAL, "Super Resolution pada Citra Udara menggunakan Convolutional Neural Network," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 9, no. 1, p. 71, Jan. 2021, doi: 10.26760/elkomika.v9i1.71.
- [10] A. Tirtana, M. Gita, T. Febriani, D. I. Masrui, and A. A. Aisyah, "Herbify: Aplikasi Perangkat Bergerak Berbasis Komputasi Awan Untuk Mengidentifikasi Tanaman Herbal Indonesia Menggunakan Cnn Model Xception," 2021.
- [11] B. Amin et al., "Brain tumor multi classification and segmentation in MRI images using deep learning," *Apr. 2023*, [Online]. Available: <http://arxiv.org/abs/2304.10039>



- [12] 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.
- [13] W. Chen, B. Yang, J. Li, and J. Wang, “An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks,” *IEEE Access*, vol. 8, pp. 178552–178562, 2020, doi: 10.1109/ACCESS.2020.3027794.
- [14] S. RIZAL, N. IBRAHIM, N. K. C. PRATIWI, S. SAIDAH, and R. Y. N. FU’ADAH, “Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 3, p. 693, Aug. 2020, doi: 10.26760/elkomika.v8i3.693.
- [15] H. Mustafa, S. F. Ali, M. Bilal, and M. S. Hanif, “Multi-Stream Deep Neural Network for Diabetic Retinopathy Severity Classification under a Boosting Framework,” *IEEE Access*, vol. 10, pp. 113172–113183, 2022, doi: 10.1109/ACCESS.2022.3217216.
- [16] S. H. Abdullah, R. Magdalena, and R. Y. N. Fu’adah, “Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus Dan Deep Learning,” *Journal Of Electrical And System Control Engineering*, vol. 5, no. 2, pp. 84–90, Feb. 2022, doi: 10.31289/jesce.v5i2.5659.
- [17] Z. Han, C. Gao, J. Liu, J. Zhang, and S. Q. Zhang, “Parameter-Efficient Fine-Tuning for Large Models: A Comprehensive Survey,” Mar. 2024, [Online]. Available: <http://arxiv.org/abs/2403.14608>
- [18] G. Thiodorus, A. Prasetia, L. A. Ardhani, and N. Yudistira, “Klasifikasi citra makanan/non makanan menggunakan metode Transfer Learning dengan model Residual Network,” *Teknologi*, vol. 11, no. 2, pp. 74–83, Jul. 2021, doi: 10.26594/teknologi.v11i2.2402.
- [19] Agus Mulyanto, Farli Rosi, Erlina Susanti, and Wajiran, “Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR),” *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, Accessed: May 19, 2025. Available: <https://colab.research.google.com>
- [20] S. N. Fadilah, D. C. R. Novitasari, and L. Hakim, “Pengaruh Reduksi Fitur Pada Klasifikasi Kanker Paru Menggunakan CNN Dengan Arsitektur GoogLeNet,” *Jurnal Fourier*, vol. 12, no. 1, pp. 20–32, Apr. 2023, doi: 10.14421/fourier.2023.121.20-32.
- [21] N. , dan S. J. Hardi, “Pengenalan Telapak Tangan Menggunakan Convolutionall Neural Network (CNN),” *Jurnal Rekayasa Perangkat Lunak*, vol. 4, no. 1, 2022.
- [22] Y. Lu et al., “Influence of the parameters of the convolutional neural network model in predicting the effective compressive modulus of porous structure,” *Front Bioeng Biotechnol*, vol. 10, Sep. 2022, doi: 10.3389/fbioe.2022.985688.
- [23] C. , W. A. P. , Astria, “Pemilihan Model Arsitektur Terbaik Dengan Mengoptimasi Learning Rate Pada Neural Network Backpropagation,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 1, 109, 2022.