

DETEKSI *DIABETIC RETINOPATHY* MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* BERBASIS *EFFICIENTNET* DAN *GRAD-CAM* PADA CITRA FUNDUS RETINA

Hendra Irawan Wijaya Kusuma^{1*}, Bagus Satrio Waluyo Poetro²

^{1,2}Universitas Islam Sultan Agung Semarang

hendrairawanwk@std.unissula.ac.id¹, bagusswp@unissula.ac.id²

Received: 30-07-2025

Revised: 10-08-2025

Approved: 16-08-2025

ABSTRAK

Retinopati diabetik merupakan salah satu komplikasi utama diabetes yang dapat menyebabkan kebutaan permanen jika tidak dideteksi secara dini. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis retinopati diabetik menggunakan algoritma Convolutional Neural Network (CNN) berbasis arsitektur EfficientNet dan visual Grad-CAM pada citra fundus retina. Dataset yang digunakan adalah APTOS 2019 Blindness Detection dengan lima klasifikasi tingkat keparahan retinopati. Proses meliputi preprocessing data, augmentasi citra, pelatihan model dengan transfer learning pada EfficientNetB3, evaluasi model melalui confusion matrix dan classification report, serta deployment menggunakan aplikasi Streamlit. Hasil evaluasi menunjukkan bahwa model mencapai akurasi validasi sebesar 75,70%, dengan performa terbaik pada kelas normal (kelas 0) dan akurasi yang masih dapat ditingkatkan pada kelas parah (kelas 3 dan 4). Integrasi Grad-CAM memberikan visualisasi yang membantu dalam interpretasi hasil prediksi. Sistem ini diharapkan dapat menjadi alat bantu diagnosis awal retinopati diabetik secara cepat dan akurat dalam praktik medis.

Kata kunci: CNN, EfficientNet, Grad-CAM, Fundus Retina, Retinopati Diabetik..

PENDAHULUAN

Diabetic retinopathy (DR) adalah penyebab utama kebutaan yang bisa dicegah di seluruh dunia. Deteksi dini perlu dukungan teknologi Artificial Intelligence (AI) untuk skrining otomatis, yang terbukti memiliki keakuratan tinggi dan efisiensi dalam implementasi klinis (Alqahtani dkk., 2025). Studi terbaru menegaskan bahwa meskipun model AI telah mencapai akurasi tinggi pada berbagai dataset, tantangan seperti ketidakseimbangan kelas, kompleksitas komputasi, dan interpretabilitas model masih menjadi hambatan utama dalam penerapannya di klinik nyata (Haq dkk., 2024). Risiko perkembangan DR sangat bervariasi di antara individu yang berbeda, sehingga sulit untuk memprediksi risiko dan mempersonalisasi skrining interval (Dai dkk., 2024). Deteksi dini dan interpretasi yang akurat sangat penting untuk mencegah progresi penyakit ini (Zahir & Adi Saputra, 2024). Menurut data dari World Health Organization (WHO), diabetes menempati peringkat ketujuh sebagai penyebab kematian pada tahun 2016. Deteksi dini retinopati diabetik sangat penting untuk mencegah perkembangan penyakit dan kehilangan penglihatan yang lebih parah.

Penyakit retinopati diabetik terjadi akibat dari kerusakan mikro-pembuluh darah akibat kadar glukosa darah yang tinggi dan tidak terkontrol dalam jangka panjang. Gejala awal retinopati diabetik sering kali tidak disadari oleh pasien, sehingga penyakit ini sering terdeteksi dalam stadium lanjut ketika kerusakan penglihatan sudah terjadi secara signifikan. Sejumlah penelitian terkini menggunakan kombinasi CNN dan Vision Transformer, atau model ensemble, untuk meningkatkan akurasi deteksi DR, dengan beberapa mencapai tingkat akurasi di atas 90% (Refat dkk., 2025) (Tewari dkk., 2025). Salah satu pendekatan yang paling banyak digunakan adalah Convolutional Neural Network (CNN) karena kemampuannya mengenali pola visual secara akurat, meskipun dalam data beresolusi tinggi (Schielein dkk., 2023). Dalam konteks

pengenalan objek, *CNN* telah terbukti efektif dalam melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi fitur, dan klasifikasi, serta dapat diterapkan pada citra resolusi tinggi dengan model distribusi nonparametric (Romario dkk., 2020).

Metode *Convolutional Neural Network* (*CNN*) adalah jenis kerangka kerja jaringan saraf tiruan yang dimaksudkan untuk mengolah dan menganalisis data berbentuk *grid*, seperti gambar. *CNN* memiliki kemampuan untuk mengenali pola dan fitur dalam data melalui lapisan konvolusi, yang memungkinkan model untuk belajar secara efektif tentang struktur dan detail visual (Satrio dkk., t.t.). Seiring dengan kemajuan teknologi pencitraan dan pengobatan, adopsi sistem klasifikasi seperti *Early Treatment of Diabetic Retinopathy Study* (*ETDRS*) dan *International Classification of Diabetic Retinopathy* (*ICDR*) telah meningkatkan akurasi diagnosis dan intervensi dini (Yang dkk., 2022).

Dalam bidang pengolahan citra medis, *Convolutional Neural Network* (*CNN*) telah digunakan secara luas untuk menganalisis citra fundus retina dalam mendeteksi retinopati diabetik. Misalnya, sebuah penelitian mengembangkan sistem deteksi level retinopati diabetik menggunakan metode *CNN* pada citra fundus mata, menunjukkan potensi *CNN* dalam klasifikasi penyakit retinopati diabetik (Abdullah dkk., 2022).

EfficientNet merupakan arsitektur *CNN* modern yang mampu meningkatkan akurasi klasifikasi dengan efisiensi tinggi Zahir & Adi Saputra (2024). Selain itu, integrasi dengan *Grad-CAM* memberikan kemampuan interpretasi visual pada hasil prediksi model, membantu tenaga medis memahami hasil klasifikasi secara lebih transparan (Daanouni dkk., 2021). Penelitian ini bertujuan membangun sistem klasifikasi otomatis DR berdasarkan *EfficientNet* dan *Grad-CAM*, serta mengevaluasi kinerjanya dalam tugas klasifikasi multikelas pada dataset APTOS 2019.

Dalam *Explainable Artificial Intelligence* (*XAI*), *Gradient-weighted Class Activation Mapping* (*Grad-CAM*) merupakan teknik untuk mengeksplorasi transparansi model dan kemampuan interpretasi, salah satu metode visualisasi yang paling populer dan banyak digunakan dalam bidang visi komputer (Swaminathan, 2025).

Dengan menggabungkan arsitektur *EfficientNet* dan teknik *Grad-CAM*, sistem deteksi dan interpretasi retinopati diabetik dapat mencapai akurasi tinggi sekaligus memberikan visual yang jelas, yang penting untuk kepercayaan dan adopsi klinis (Abdullah dkk., 2022). Implementasi metode ini diharapkan dapat membantu tenaga medis dalam pengambilan keputusan yang lebih akurat dan cepat, sehingga mendukung deteksi dini dan perawatan yang lebih efektif bagi pasien dengan risiko retinopati diabetik. Dalam studi (Nayak dkk., 2022). penerapan *EfficientNet* untuk klasifikasi *DR* menghasilkan performa yang signifikan dengan kompleksitas komputasi yang rendah, terutama dalam pengklasifikasian lima tingkatan *DR*.

Berdasarkan hasil penelitian dari (Hidayah dkk., 2025), dengan penambahan proses augmentasi pada skenarionya yang kedua menghasilkan nilai akurasi yang lebih tinggi dan stabil antara nilai training dan validasi, dibandingkan dengan skenario pertama yang memiliki nilai akurasi dan *loss training* dengan akurasi dan *loss validasi* kurang stabil, serta selisih nilai *training* dan validasi yang cukup jauh. Hal ini bisa saja menjadi indikasi *over-fitting*. Selanjutnya berdasarkan metrik evaluasi, menunjukkan bahwa skenario kedua memiliki performa yang cukup baik dengan akurasi yang lebih yakni sekitar 76% dibanding dengan skenario pertama sekitar 73%. Namun, dari kedua skenario memiliki *precision* dan *recall* yang tidak seimbang, menunjukkan bahwa model mungkin masih memiliki kecenderungan untuk membuat kesalahan dalam memprediksi kelas tertentu.

Sedangkan berdasarkan *classification report* dan *confusion matrix*, menunjukkan bahwa keduanya memiliki kinerja yang bervariasi untuk setiap kelas. Pada skenario pertama model berkinerja sangat baik untuk kelas "No_DR" tetapi sangat buruk untuk kelas "Proliferate_DR" dan "Severe". Sedangkan pada skenario kedua model berkinerja sangat baik pada kelas "Moderate" dan "Mild", namun perlu ditingkatkan untuk kelas-kelas yang lain. Terutama untuk kelas "No_DR", "Severe", dan "Proliferate_DR". Berdasarkan penelitian tersebut, dapat ditarik Kesimpulan yakni penambahan proses augmentasi memberikan peningkatan pada hasil klasifikasi, khususnya data dengan multi-kelas dan variasi yang banyak.

Berdasarkan hasil penelitian dari (Arora dkk., 2024) model *EfficientNetB0* mencapai akurasi maksimum 97,11% dengan kerugian sebesar 0,1596. Setelah pelatihan selama 40 *epoch*, dengan menerapkan teknik augmentasi data. Augmentasi data, termasuk pergeseran acak, rotasi, dan *zoom*, memberikan peningkatan kecil pada kinerja validasi, seperti yang tercermin dari akurasi rata-rata 86,53 dan kerugian rata-rata 0,5663, Setelah 40 *epoch*, model *EfficientNetB0* mencapai akurasi pelatihan rata-rata 86,53% dengan augmentasi data yang diterapkan. Sebagai perbandingan, metode fusi fitur multi-skala, meskipun intensif komputasi, menunjukkan ketahanan dalam klasifikasi retinopati diabetik, mencapai akurasi 83,6%.

Penelitian terbaru menunjukkan bahwa model ensemble berbasis *EfficientNet* mampu mencapai akurasi hingga 99 % pada berbagai dataset seperti APTOS 2019 dan *EyePacs*, sekaligus menyediakan penjelasan visual penting melalui *Grad-CAM* mendukung potensi klinisnya untuk diagnosis otomatis DR secara *real-time* (*Open Access*) (Sharma & Lalwani, 2025). Selain itu, penggunaan *EfficientNetB0* dalam sistem *end-to-end* yang menggabungkan deteksi DR dan DME melalui *Grad-CAM* terbukti meningkatkan efisiensi interpretasi gambar *fluorescein angiografi* (FFA) (Long dkk., 2025). Upaya terbaru lainnya memperkenalkan arsitektur *FastEffNet*, yang memanfaatkan *knowledge distillation* berbasis *transformer* untuk meningkatkan klasifikasi tingkat keparahan DR secara efisien (Rautaray dkk., 2025). Model tersebut efektif menangkap fitur retina lokal dan global, kemampuan yang berharga untuk identifikasi fitur yang halus. Namun, *EfficientNetB0* mempertahankan akurasi tinggi sambil menawarkan tuntutan komputasi yang jauh lebih rendah, menjadikannya sangat cocok untuk lingkungan dengan sumber daya terbatas. Kedua model, *EfficientNetB0* dan model penggabungan fitur multi-skala Luo et al.25, dievaluasi pada tugas klasifikasi retinopati diabetik, dengan masing-masing menunjukkan keunggulan yang berbeda pada metrik kinerja kunci. Model *EfficientNetB0*, yang memanfaatkan bobot yang telah dilatih sebelumnya dan arsitektur yang dioptimalkan, mencapai akurasi maksimum yang mengesankan sebesar 97,11% dan menunjukkan efisiensi komputasi yang lebih tinggi. Model Luo25, meskipun unggul dalam ekstraksi fitur pada skala spasial berbeda dengan presisi 81,9%, menimbulkan biaya pemrosesan yang lebih tinggi. Perbandingan ini menunjukkan bahwa meskipun kedua model efektif dalam menangani gambar retina, *EfficientNetB0* menawarkan keseimbangan optimal antara efisiensi komputasi dan akurasi.

METODE PENELITIAN

Adapun metode penelitian yang digunakan oleh penelitian tersebut, yaitu sebagai berikut:

1. Pengumpulan Data dan Persiapan Data


Pada tahap ini Dataset yang digunakan dalam penelitian ini adalah dataset citra

medis citra fundus retina yang telah terlabeli. Dataset ini diperoleh dari Kaggle <https://www.kaggle.com/c/aptos2019-blindness-detection/overview>

2. Preprocessing Data


Proses *preprocessing* diawali dengan membaca dan memuat citra berformat .png dari direktori dataset. Selanjutnya, setiap citra diubah ukurannya menjadi 224x224 piksel untuk menyesuaikan dengan *input layer* dari model *EfficientNetB3*. Warna citra juga dikonversi ke format RGB. Selain itu, dilakukan augmentasi data menggunakan teknik *rotasi*, *zoom*, dan *flip horizontal*. Augmentasi ini bertujuan untuk meningkatkan keragaman data pelatihan dan mengurangi risiko *overfitting*, sehingga model dapat mengenali fitur penting dari berbagai variasi gambar (Navaneethan dkk., 2024). Serta menggunakan *class weights* agar model lebih sensitif terhadap kelas minoritas. Dengan *preprocessing* yang optimal, data masukan menjadi lebih representatif dan siap digunakan pada proses pelatihan model CNN untuk deteksi *diabetic retinopathy*.

3. Pelatihan Model



Gambar 1 Proses *Training* CNN *EfficientNet*

Proses dimulai dari langkah *Load Dataset*, di mana data gambar dikumpulkan dan disiapkan untuk pelatihan. Setelah itu, data menjalani tahap *Preprocess Data*, yang meliputi *resize* gambar ke ukuran yang sesuai (224x224 piksel untuk *EfficientNetB3*), normalisasi nilai piksel, serta augmentasi data untuk meningkatkan generalisasi model. Tahap berikutnya adalah *Load EfficientNetB3*, yaitu memuat arsitektur *EfficientNetB3*, biasanya dengan bobot awal dari *ImageNet* dan menyesuaikannya dengan jumlah kelas pada dataset kita. Terakhir, model yang telah terlatih disimpan pada tahap *Save Model*, agar bisa digunakan untuk prediksi atau *deployment* ke sistem produksi. Seluruh proses berjalan secara berurutan dan sistematis untuk membangun model klasifikasi gambar yang efisien dan akurat.



Gambar 2 Arsitektur Model *EfficientNetB3*

Diagram arsitektur model CNN berbasis *EfficientNetB3* yang digunakan dalam


penelitian ini. Arsitektur terdiri dari base model *pretrained*, diikuti *Global Average Pooling*, *Dense layer* berukuran 256 unit, *Dropout*, dan *output layer Softmax* untuk klasifikasi 5 kelas. *Grad-CAM* digunakan pada *output* sebagai metode interpretabilitas.

4. Evaluasi Model

Parameter evaluasi utama yang digunakan meliputi nilai akurasi, *loss* (fungsi kerugian), serta analisis lebih mendalam melalui *confusion matrix* dan *classification report*. *Confusion matrix* digunakan untuk melihat distribusi prediksi model terhadap kelas yang sebenarnya, sehingga dapat dianalisis sejauh mana model berhasil membedakan berbagai tingkat keparahan *diabetic retinopathy*. Selain itu, *classification report* menghasilkan metrik seperti *precision*, *recall*, dan *F1-score* untuk masing-masing kelas, yang sangat penting untuk memahami kekuatan dan kelemahan model terhadap setiap kategori.

5. Deployment Model

Proses ini dilakukan menggunakan *framework Streamlit*. Gambar yang diunggah akan melalui proses *preprocessing* serupa seperti pada tahap pelatihan model, kemudian hasil prediksi ditampilkan secara *real-time*. Selain memberikan hasil klasifikasi, aplikasi juga menyertakan visual berbasis *Grad-CAM* (*Gradient-weighted Class Activation Mapping*), yang menyoroti area penting pada citra yang mempengaruhi keputusan model.



Gambar 3 Flowchart alur sistem

Tahapan alur kerja *streamlit* tersebut dijelaskan sebagai berikut :

- Pertama *user* mengakses link *streamlit* dari kreator aplikasi web.
- Pada fitur *upload* gambar, *user* memasukkan gambar retina yang ingin diklasifikasikan.
- Setelah gambar retina terproses maka hasil prediksi akan mengklasifikasikan

apakah gambar tersebut terkategori class normal, ringan, sedang, parah, atau sangat parah, selain itu terdapat probabilitas hasil dari setiap kelas. Setelah prediksi berhasil, visualisasi *Grad-CAM* akan muncul pada bagian bawah.

HASIL DAN PEMBAHASAN

1. Hasil Pengumpulan Data



Gambar 4 Contoh citra dari masing-masing kelas

Dataset yang diperoleh dari APTOS 2019 *Blindness Detection* dari platform Kaggle. dalam format file ZIP memiliki dua komponen utama, yaitu file *train.csv* yang berisi label dan metadata gambar, serta folder *train_images* yang berisi citra retina dalam format *.png*. File CSV mengandung dua kolom, yaitu *id_code* sebagai nama file gambar, dan diagnosis sebagai label kelas (dari 0 hingga 4).

Tabel 1 Labelling pada dataset

| Kode Kelas | Tingkat DR | Keterangan Medis |
|------------|---------------------------------------|---|
| 0 | <i>NO DR</i> | Retina tidak menunjukkan tanda-tanda retinopati diabetik. Tidak ada kelainan pada pembuluh darah mata. Kondisi ini dianggap normal. |
| 1 | <i>Mild DR (Ringan)</i> | Terdapat sedikit mikroaneurisma (pelebaran kecil pada pembuluh darah retina), tanda awal dari DR. Tidak ada perdarahan atau eksudat keras. |
| 2 | <i>Moderate DR (Sedang)</i> | Ditemukan lebih banyak mikroaneurisma dan mungkin disertai perdarahan ringan atau eksudat keras. Tanda-tanda kerusakan pembuluh darah mulai terlihat. |
| 3 | <i>Severe DR (Parah)</i> | Perdarahan retina yang luas, banyak mikroaneurisma, dan kerusakan pembuluh darah yang signifikan. Risiko tinggi berkembang ke retinopati proliferatif. |
| 4 | <i>Poliferative DR (Sangat Parah)</i> | Terdapat pertumbuhan pembuluh darah abnormal di retina (neovaskularisasi), yang dapat menyebabkan perdarahan vitreous, jaringan parut, atau bahkan kebutaan permanen. |

2. Data Preprocessing


Proses *preprocessing* dilakukan dengan semua gambar telah di-*resize* ke ukuran 224x224 piksel dan dikonversi ke format RGB menggunakan *OpenCV* untuk memastikan konsistensi warna. Kemudian dilakukan augmentasi data menggunakan *ImageDataGenerator*, yang diterapkan pada citra retina dengan *rotasi*, *zoom*, dan *flip horizontal*. Augmentasi ini membantu meningkatkan keragaman data dan mencegah *overfitting* selama pelatihan. Dataset APTOS 2019 memiliki ketidakseimbangan distribusi kelas (*imbalance*). Distribusi awal jumlah sampel per kelas dihitung menggunakan `value_counts()`. Untuk mengatasi

masalah ini, dilakukan *upsampling* terhadap kelas minoritas dengan menggandakan sampel secara acak (*resampling* dengan `replacement=True`) hingga jumlah setiap kelas sama dengan kelas mayoritas. Data juga dibagi menjadi dua *subset*: 80% untuk pelatihan dan 20% untuk validasi.

3. Pelatihan Model

Proses dimulai dengan mendefinisikan input layer menggunakan `Input(shape=(224, 224, 3))`, yang menunjukkan bahwa citra masukan berukuran 224x224 piksel dengan tiga saluran warna (RGB), sesuai dengan standar input *EfficientNet*. Selanjutnya, digunakan model *EfficientNetB3* dari Keras dengan parameter `include_top=False` untuk menghilangkan lapisan klasifikasi bawaan dari *ImageNet*, dan `weights='imagenet'` yang berarti model menggunakan bobot prelatih dari dataset *ImageNet* sebagai bagian dari pendekatan *transfer learning*. Kemudian dilewatkan ke dalam *GlobalAveragePooling2D*, yang berfungsi mengubah fitur spasial menjadi vektor satu dimensi tanpa parameter tambahan, diikuti oleh *Dropout(0.4)* untuk mengurangi risiko *overfitting* dengan menonaktifkan 40% neuron secara acak saat proses pelatihan. Setelah itu, model memiliki output layer berupa `Dense(5, activation='softmax')`. Model akhir dikompilasi menggunakan *optimizer Adam*, yang merupakan algoritma efisien untuk mengatur bobot model, dengan fungsi kerugian *categorical_crossentropy* yang sesuai untuk klasifikasi multi-kelas, serta metrik akurasi untuk mengevaluasi performa model selama pelatihan.

4. Evaluasi Model




Gambar 5 Grafik akurasi dan *loss* dari pelatihan

Dari gambar 5 menunjukkan bahwa nilai *train accuracy* meningkat secara konsisten dari sekitar 0,63 pada *epoch* pertama hingga mendekati 1,00 pada *epoch* ke-10, dan kemudian stabil hingga akhir pelatihan. *Validation accuracy* pada awalnya berada di kisaran 0,20–0,65 dengan fluktuasi pada *epoch* ke-2 hingga ke-5, sebelum akhirnya meningkat signifikan pada *epoch* ke-6 dan stabil di kisaran 0,94–0,96 hingga *epoch* terakhir. Pola ini mengindikasikan bahwa model membutuhkan beberapa *epoch* awal untuk menyesuaikan bobot dan mempelajari representasi yang baik dari data, sebelum akhirnya mencapai performa yang stabil baik pada data latih maupun data validasi.

Pada grafik *loss*, *train loss* berada pada nilai yang sangat rendah sejak awal dan terus stabil mendekati nol, sedangkan *validation loss* mengalami lonjakan yang sangat tinggi pada *epoch* awal (lebih dari 5000) sebelum turun drastis mendekati nol mulai *epoch* ke-3 dan stabil hingga akhir pelatihan. Lonjakan ekstrem pada *validation loss* di awal pelatihan ini kemungkinan disebabkan oleh *batch* awal data

validasi yang tidak representatif atau kombinasi inisialisasi bobot dan *learning rate* yang menyebabkan prediksi awal jauh dari label sebenarnya. Setelah proses optimisasi berlangsung, *validation loss* menurun tajam dan stabil, selaras dengan meningkatnya *validation accuracy*.

Secara keseluruhan, meskipun terdapat anomali pada *validation loss* di awal pelatihan, tren akurasi yang stabil tinggi dan *loss* yang rendah pada akhir pelatihan menunjukkan bahwa model telah mampu mempelajari pola data dengan baik dan menghasilkan kinerja yang konsisten pada data latih maupun data validasi.



Gambar 6 *Confusion matrix*

Dari gambar 6 menunjukkan distribusi prediksi model terhadap label sebenarnya untuk lima kelas tingkat keparahan *diabetic retinopathy*. Secara umum, model mampu mengklasifikasikan sebagian besar citra dengan benar, terlihat dari dominasi angka pada diagonal utama matriks. Untuk kelas 0, terdapat 219 prediksi benar dari total 222 sampel, dengan hanya sedikit kesalahan klasifikasi ke kelas 1 dan 2. Kelas 1 juga memiliki kinerja yang tinggi dengan 209 prediksi benar dari 216 sampel, walaupun terdapat sebagian kecil citra yang salah diklasifikasikan ke kelas 0, 2, 3, dan 4.

Kinerja pada kelas 2 relatif baik dengan 188 prediksi benar dari 218 sampel, meskipun terdapat kesalahan klasifikasi ke kelas 1, 3, dan 4, dengan jumlah tertinggi salah ke kelas 1 (19 kasus). Hal ini menunjukkan bahwa citra pada kelas 2 memiliki kemiripan visual dengan kelas 1 sehingga model kadang mengalami kebingungan dalam membedakannya. Untuk kelas 3, model menunjukkan akurasi yang hampir sempurna dengan 221 prediksi benar dari 222 sampel, dan hanya 1 kesalahan ke kelas 4. Demikian pula pada kelas 4, model berhasil memprediksi 223 dari 226 sampel dengan benar, dengan kesalahan hanya pada kelas 3.

Secara keseluruhan, *confusion matrix* ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik di semua kelas, dengan tingkat kesalahan

relatif rendah. Kesalahan yang terjadi sebagian besar merupakan *misclassification* ke kelas yang berdekatan tingkat keparahannya, yang dapat dimaklumi mengingat kemiripan karakteristik visual pada citra retina antar kelas tersebut.

Tabel 2 *Classification Report*

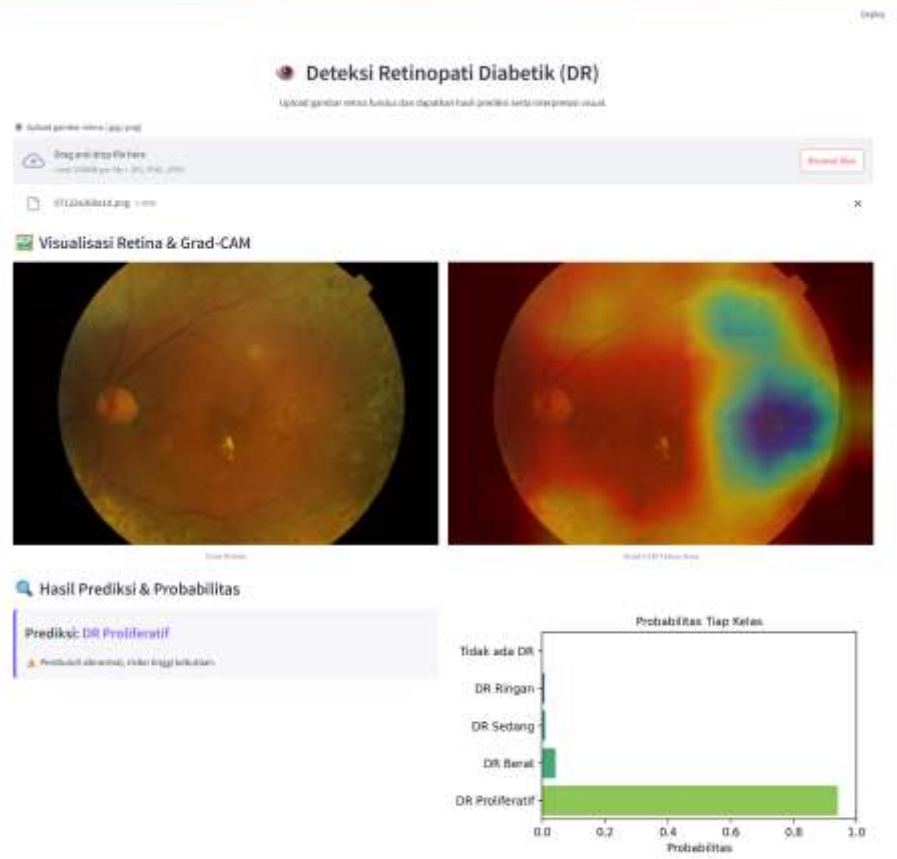
| Kelas | Deskripsi | Precision | Recall | F1-Score |
|---------------------|----------------------|-----------|--------|----------|
| 0 | Tidak ada DR | 1.00 | 0.99 | 0.99 |
| 1 | DR ringan (Mild) | 0.91 | 0.97 | 0.94 |
| 2 | DR sedang (Moderate) | 0.97 | 0.86 | 0.91 |
| 3 | DR berat (Severe) | 0.96 | 1.00 | 0.98 |
| 4 | DR sangat berat | 0.97 | 0.99 | 0.98 |
| <i>Accuracy</i> | | | | 0.96 |
| <i>Macro avg</i> | | 0.96 | 0.96 | 0.96 |
| <i>Weighted avg</i> | | 0.96 | 0.96 | 0.96 |

Dari tabel 2 menunjukkan bahwa model memiliki kinerja klasifikasi yang sangat baik pada semua kelas *diabetic retinopathy*. Pada kelas 0, model mencapai nilai *precision* sempurna sebesar 1,00 dan *recall* sebesar 0,99, menghasilkan *f1-score* 0,99 yang menunjukkan kemampuan mendeteksi kasus tanpa retinopati secara hampir sempurna tanpa banyak kesalahan prediksi positif palsu. Kelas 1 memiliki *precision* 0,91 dan *recall* 0,97 dengan *f1-score* 0,94, yang mengindikasikan bahwa meskipun kemampuan model dalam menemukan semua kasus kelas ini sangat baik, terdapat sebagian prediksi yang keliru mengklasifikasikan citra dari kelas lain sebagai kelas 1.

Pada kelas 2, *precision* tinggi sebesar 0,97 menunjukkan bahwa prediksi kelas ini jarang salah, namun *recall* lebih rendah di angka 0,86, yang berarti masih ada sejumlah kasus kelas 2 yang tidak terdeteksi dan diklasifikasikan ke kelas lain. Kelas 3 dan kelas 4 menunjukkan performa yang sangat baik dengan *precision* di atas 0,96 dan *recall* hampir sempurna (1,00 untuk kelas 3 dan 0,99 untuk kelas 4), menghasilkan *f1-score* 0,98 untuk keduanya.

Secara keseluruhan, model memperoleh akurasi total sebesar 0,96, dengan nilai *macro average* dan *weighted average* yang sama, yaitu *precision*, *recall*, dan *f1-score* masing-masing sebesar 0,96. Nilai *macro average* yang tinggi menunjukkan bahwa performa model konsisten di semua kelas tanpa bias signifikan terhadap kelas tertentu, sementara *weighted average* yang sama menunjukkan bahwa model juga mempertahankan kinerja tinggi meskipun mempertimbangkan distribusi jumlah sampel di tiap kelas. Hasil ini membuktikan bahwa model mampu mengklasifikasikan citra retina secara akurat dan konsisten pada semua tingkat keparahan *diabetic retinopathy*.

5. Hasil Implementasi



Gambar 7 Hasil Implementasi

Pada gambar 7 menunjukkan tampilan hasil implementasi sistem deteksi Retinopati Diabetik berbasis *Convolutional Neural Network* (CNN) dengan dukungan visualisasi *Grad-CAM*. Setelah pengguna mengunggah citra retina fundus melalui antarmuka aplikasi, sistem secara otomatis menampilkan hasil analisis yang terdiri dari visualisasi gambar retina asli, peta panas (*heatmap*) *Grad-CAM*, prediksi klasifikasi, serta probabilitas dari masing-masing kelas.

Pada bagian kiri atas ditampilkan citra retina, di mana terlihat struktur pembuluh darah dan adanya beberapa kelainan seperti bercak-bercak yang dapat mengindikasikan pembentukan pembuluh darah baru yang tidak normal. Gambar di sebelah kanannya merupakan visualisasi *Grad-CAM*, yang menunjukkan area yang paling berkontribusi terhadap keputusan model. Warna biru-ungu serta banyak bercak-bercak di bagian kanan retina menunjukkan area yang sangat memengaruhi klasifikasi, mengindikasikan kemungkinan adanya pembuluh darah abnormal atau jaringan baru yang menjadi ciri khas DR stadium lanjut. Model memberikan hasil prediksi: DR Proliferatif, dengan deskripsi "Pembuluh abnormal, risiko tinggi kebutaan". Ini merupakan tingkat keparahan tertinggi dalam klasifikasi Retinopati Diabetik, di mana terjadi pertumbuhan pembuluh darah baru yang rapuh dan mudah pecah, sehingga sangat berisiko menyebabkan perdarahan hebat dalam retina dan bahkan lepasnya retina dari dinding mata.

Hasil prediksi ini didukung oleh grafik probabilitas kelas, di mana kelas DR Proliferatif memiliki probabilitas tertinggi secara signifikan, mendekati angka 1.0.

Kelas-kelas lainnya seperti DR Berat, Sedang, dan Ringan hanya menunjukkan probabilitas yang sangat kecil, menandakan keyakinan tinggi dari model terhadap prediksi tersebut.

Dengan demikian, implementasi sistem ini menunjukkan bahwa model tidak hanya mampu mendeteksi keberadaan DR, tetapi juga mengklasifikasikan tingkat keparahannya secara detail dan dapat diandalkan. Interpretasi visual *Grad-CAM* juga membantu memberikan penjelasan tambahan mengenai area retina yang menjadi fokus perhatian model, mendukung pengambilan keputusan oleh dokter secara lebih akurat dan cepat.

KESIMPULAN

Model klasifikasi *diabetic retinopathy* berbasis arsitektur *EfficientNetB3* berhasil mencapai akurasi sebesar 96% dan mampu mengklasifikasikan lima tingkat keparahan penyakit secara efektif. Integrasi *Grad-CAM* memberikan visualisasi prediksi yang meningkatkan interpretabilitas model, tetapi masih ada beberapa hasil yang kurang maksimal dalam visualisasinya. Implementasi sistem dalam bentuk aplikasi Streamlit juga mempermudah penggunaannya. Kinerja model menunjukkan hasil yang sangat baik terutama pada kelas “tidak ada DR” (kelas 0) dengan *precision* sempurna (1,00) dan *recall* tinggi (0,99). Namun, tantangan masih terlihat pada kelas yang memiliki kemiripan visual, seperti kelas *mild* (kelas 1) dan *moderate* (kelas 2), di mana meskipun kelas 1 memiliki *recall* tinggi (0,97), nilai *precision*-nya lebih rendah (0,91), dan kelas 2 memiliki *recall* yang relatif lebih rendah (0,86) meskipun *precision*-nya tinggi (0,97). Sementara itu, kelas *severe* (kelas 3) dan *proliferative* (kelas 4) menunjukkan performa hampir sempurna dengan *recall* masing-masing 1,00 dan 0,99 serta *precision* di atas 0,96. Hal ini menandakan bahwa peningkatan akurasi pada kelas dengan perbedaan visual yang lebih halus masih menjadi ruang pengembangan yang penting untuk ke depan.

DAFTAR PUSTAKA

- Abdullah, S. H., Magdalena, R., & Fu'adah, R. Y. N. (2022). Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus Dan Deep Learning. *Journal of Electrical and System Control Engineering*, 5(2), 84–90. <https://doi.org/10.31289/jesce.v5i2.5659>
- Alqahtani, A. S., Alshareef, W. M., Aljadani, H. T., Hawsawi, W. O., & Shaheen, M. H. (2025). The efficacy of artificial intelligence in diabetic retinopathy screening: a systematic review and meta-analysis. *International Journal of Retina and Vitreous*, 11(1). <https://doi.org/10.1186/s40942-025-00670-9>
- Arora, L., Singh, S. K., Kumar, S., Gupta, H., Alhalabi, W., Arya, V., Bansal, S., Chui, K. T., & Gupta, B. B. (2024). Ensemble deep learning and EfficientNet for accurate diagnosis of diabetic retinopathy. *Scientific Reports*, 14(1), 1–16. <https://doi.org/10.1038/s41598-024-81132-4>
- Daanouni, O., Cherradi, B., & Tmiri, A. (2021). Automatic Detection of Diabetic Retinopathy Using Custom CNN and Grad-CAM. *Advances in Intelligent Systems and Computing*, 1188(January), 15–26. https://doi.org/10.1007/978-981-15-6048-4_2
- Dai, L., Sheng, B., Chen, T., Wu, Q., Liu, R., Cai, C., Wu, L., Yang, D., Hamzah, H., Liu, Y., Wang, X., Guan, Z., Yu, S., Li, T., Tang, Z., Ran, A., Che, H., Chen, H., Zheng, Y., ... Jia, W. (2024). A deep learning system for predicting time to progression of

- diabetic retinopathy. *Nature Medicine*, 30(2), 584–594. <https://doi.org/10.1038/s41591-023-02702-z>
- Haq, N. U., Waheed, T., Ishaq, K., Hassan, M. A., Safie, N., Elias, N. F., & Shoaib, M. (2024). Computationally efficient deep learning models for diabetic retinopathy detection: a systematic literature review. *Artificial Intelligence Review*, 57(11). <https://doi.org/10.1007/s10462-024-10942-9>
- Hidayah, A. N., Adiputra, F., & Koeshardianto, M. (2025). *Klasifikasi Citra Diabetic Retinopathy Menggunakan CNN (Convolutional Neural Network) Dengan Arsitektur VGG-16*. 9(2), 2451–2458.
- Long, X., Gan, F., Fan, H., Qin, W., Li, X., Ma, R., Wang, L., Hu, R., Xie, Y., Chen, L., Cao, J., Shao, Y., Liu, K., & You, Z. (2025). EfficientNetB0-Based End-to-End Diagnostic System for Diabetic Retinopathy Grading and Macular Edema Detection. *Diabetes, Metabolic Syndrome and Obesity*, 18(April), 1311–1321. <https://doi.org/10.2147/DMSO.S506494>
- Navaneethan, S., Pardhiv, A., & Teja, K. (2024). Automated Diabetic Retinopathy Detection and Multi-Stage Classification Using Convolutional Neural Networks. *Proceedings of the 2024 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2024*, 6(5), 1–24. <https://doi.org/10.1109/ICSES63760.2024.10910687>
- Nayak, D. R., Padhy, N., Mallick, P. K., Zymbler, M., & Kumar, S. (2022). Brain Tumor Classification Using Dense Efficient-Net. *Axioms*, 11(1). <https://doi.org/10.3390/axioms11010034>
- Rautaray, J., Ali, A. B. M., Kandpal, M., Mishra, P., Rashid, R. F., Alimova, F., Kallel, M., & Batool, N. (2025). Leveraging FastViT based knowledge distillation with EfficientNet-B0 for diabetic retinopathy severity classification. *SLAS Technology*, 33. <https://doi.org/10.1016/j.slast.2025.100325>
- Refat, S. R., Raha, Z. S., Sarker, S., Preotee, F. F., Rahman, MD. M., Muhammad, T., & Alam, M. S. (2025). *VR-FuseNet: A Fusion of Heterogeneous Fundus Data and Explainable Deep Network for Diabetic Retinopathy Classification*. <http://arxiv.org/abs/2504.21464>
- Romario, M. H., Ihsanto, E., & Kadarina, T. M. (2020). Sistem Hitung dan Klasifikasi Objek dengan Metode Convolutional Neural Network. *Jurnal Teknologi Elektro*, 11(2), 108. <https://doi.org/10.22441/jte.2020.v11i2.007>
- Satrio, B., Poetro, W., Mulyono, S., & Pramesti, V. A. (2024). *Prediksi Penyakit Batu Ginjal dengan Menerapkan Convolutional Neural Network*. 153–162.
- Schielein, M. C., Christl, J., Sitaru, S., Pilz, A. C., Kaczmarczyk, R., Biedermann, T., Lasser, T., & Zink, A. (2023). Outlier detection in dermatology: Performance of different convolutional neural networks for binary classification of inflammatory skin diseases. *Journal of the European Academy of Dermatology and Venereology*, 37(5), 1071–1079. <https://doi.org/10.1111/jdv.18853>
- Sharma, N., & Lalwani, P. (2025). A multi model deep net with an explainable AI based framework for diabetic retinopathy segmentation and classification. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-93376-9>
- Swaminathan, R. (2025). *An Attention Infused Deep Learning System with Grad-CAM Visualization for Early Screening of Glaucoma*. <http://arxiv.org/abs/2505.17808>
- Tewari, Y., Singh Parihar, N., Rautela, K., Kaundal, N., Diwakar, M., & Pandey, N. K. (2025). *Diabetic Retinopathy Detection and Analysis with Convolutional*

- Neural Networks and Vision Transformer.* 1(1).
<https://doi.org/10.62762/BISH.2025.724307>
- Yang, Z., Tan, T. E., Shao, Y., Wong, T. Y., & Li, X. (2022). Classification of diabetic retinopathy: Past, present and future. *Frontiers in Endocrinology*, 13(December), 1–18. <https://doi.org/10.3389/fendo.2022.1079217>
- Zahir, M., & Adi Saputra, R. (2024). Deteksi Penyakit Retinopati Diabetes Menggunakan Citra Mata Dengan Implementasi Deep Learning Cnn. *Jurnal Teknoinfo*, 18(1), 121–132.
<https://www.kaggle.com/datasets/gunavenkatdoddi/eye-diseases-classification>