

## **Pengaruh preprocessing citra retina pada klasifikasi diabetic retinopathy berbasis prototypical network**

**Abi Eka Putra Wulyono<sup>1</sup>, Faisal Muttaqin<sup>\*2</sup>, Budi Mukhamad Mulyo<sup>3</sup>**

Email: <sup>1</sup>[22081010190@student.upnjatim.ac.id](mailto:22081010190@student.upnjatim.ac.id), <sup>2</sup>[faisalmuttaqin.if@upnjatim.ac.id](mailto:faisalmuttaqin.if@upnjatim.ac.id), <sup>3</sup>[budi.m.mulyo.fasilkom@upnjatim.ac.id](mailto:budi.m.mulyo.fasilkom@upnjatim.ac.id)

<sup>123</sup>Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jawa Timur

Diterima: 05 April 2020 | Direvisi: 05 Mei 2020 | Disetujui: 27 Mei 2020

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,

Universitas Muhammadiyah Riau, Indonesia

### **Abstrak**

*Diabetic retinopathy* merupakan komplikasi diabetes yang dapat menyebabkan kerusakan retina progresif hingga kebutaan permanen. Deteksi dini melalui klasifikasi otomatis citra fundus menjadi penting, namun menghadapi tantangan berupa variasi kualitas citra, *noise* latar belakang, serta dominasi warna merah kekuningan yang mengurangi visibilitas lesi. *Prototypical network* telah menunjukkan kinerja baik pada skenario *few-shot learning*, tetapi belum banyak dikombinasikan dengan tahap *preprocessing* khusus. Penelitian ini mengusulkan metode klasifikasi *diabetic retinopathy* menggunakan *prototypical network* yang diperkuat *preprocessing* berupa *modified circle crop* untuk menghilangkan area tidak relevan dan *enhanced green channel* untuk meningkatkan kontras lesi mikrovaskuler. Eksperimen dilakukan pada *dataset* APTOS 2019 yang terdiri dari 3662 citra dengan pembagian 2929 data latih dan 733 data uji menggunakan skema 5-way 5-shot. Hasil menunjukkan bahwa *preprocessing* meningkatkan *accuracy* dari 64.53 persen menjadi 71.35 persen serta *quadratic weighted kappa* dari 0.5712 menjadi 0.6990. Temuan ini menunjukkan bahwa *preprocessing* efektif meningkatkan kualitas representasi fitur dan performa klasifikasi pada kondisi data terbatas.

**Kata kunci:** *diabetic retinopathy, prototypical network, circle crop, green channel, few-shot learning*

### ***Impact of retinal image preprocessing on diabetic retinopathy classification using prototypical networks***

#### **Abstract**

*Diabetic retinopathy is a diabetes complication that can lead to progressive retinal damage and permanent blindness. Early detection through automated fundus image classification is essential but challenged by varying image quality, background noise, and color dominance that reduces lesion visibility. Prototypical networks have demonstrated good performance in few-shot learning settings, yet specialized preprocessing is rarely explored. This study proposes a prototypical network enhanced with modified circle crop to remove irrelevant regions and enhanced green channel to improve microvascular lesion contrast. Experiments were conducted on the APTOS 2019 dataset consisting of 3,662 images, split into 2,929 training and 733 testing samples, using a 5-way 5-shot configuration. The proposed preprocessing increases accuracy from 64.53 percent to 71.35 percent and improves quadratic weighted kappa from 0.5712 to 0.6990. These results indicate that preprocessing enhances feature representation and classification performance under limited data conditions.*

**Keywords:** *diabetic retinopathy, prototypical network, circle crop, green channel, few-shot learning*

## 1. PENDAHULUAN

*Diabetic retinopathy* (DR) merupakan komplikasi mikrovaskular dari diabetes mellitus yang menyerang pembuluh darah retina dan menjadi penyebab utama kebutaan pada populasi usia produktif di seluruh dunia. Menurut [1], prevalensi *diabetic retinopathy* terus meningkat seiring dengan epidemi diabetes global. Penelitian [2] menyebutkan bahwa 2.6 juta orang mengalami kebutaan akibat *diabetic retinopathy*. Deteksi dini melalui skrining fundus retina sangat penting karena progresivitas penyakit dapat dicegah dengan intervensi tepat waktu seperti laser *photocoagulation* atau injeksi anti-VEGF. Namun demikian, pemeriksaan manual oleh *ophthalmologist* memiliki keterbatasan dalam hal waktu, biaya, dan ketersediaan tenaga ahli terutama di daerah dengan akses layanan kesehatan terbatas [3].

Perkembangan teknologi *deep learning* telah membuka peluang besar dalam otomatisasi deteksi *diabetic retinopathy* melalui analisis citra fundus retina. *Convolutional neural network* (CNN) seperti *ResNet*, VGG, dan *EfficientNet* telah terbukti mampu mengklasifikasikan tingkat keparahan *diabetic retinopathy* dengan *accuracy* tinggi [4]. Namun, metode-metode tersebut umumnya memerlukan data pelatihan dalam jumlah besar dan cenderung mengalami penurunan performa signifikan ketika dihadapkan pada skenario *few-shot learning* dimana jumlah sampel pelatihan per kelas sangat terbatas. Kondisi ini sering terjadi dalam praktik klinis, terutama untuk kelas dengan tingkat keparahan tertentu yang jarang ditemukan.

*Prototypical network* merupakan pendekatan *metric learning* yang dirancang khusus untuk mengatasi tantangan *few-shot learning* dengan cara mempelajari representasi *embedding* dan mengklasifikasikan sampel berdasarkan jarak terhadap *prototype* setiap kelas [5]. Penelitian sebelumnya dalam [6] menunjukkan bahwa *prototypical network* dengan *auxiliary regularization* mampu mencapai *accuracy* 89.2% pada klasifikasi citra medis dengan *setting 5-way 5-shot*, melampaui metode *Baseline* sebesar 4.3%. Studi lain dalam [7] menggunakan *dual-channel prototype network* untuk klasifikasi patologi dengan *few-shot learning* dan memperoleh peningkatan *F1-score* sebesar 6.8% dibandingkan *prototypical network* standar. Metode ini telah menunjukkan hasil yang signifikan pada berbagai aplikasi citra medis dengan data terbatas.

Meskipun *prototypical network* memiliki keunggulan dalam skenario data terbatas, performa klasifikasi *diabetic retinopathy* masih dipengaruhi oleh kualitas citra fundus yang bervariasi. Citra fundus retina umumnya memiliki karakteristik berupa area hitam tidak relevan di sekitar lingkaran retina akibat keterbatasan *field of view* kamera fundus, serta dominasi kanal warna merah dan kuning yang dapat menutupi visibilitas lesi mikrovaskuler seperti mikroaneurisma dan eksudat [8]. Penelitian sebelumnya menunjukkan bahwa *preprocessing* seperti *background removal* dan peningkatan kontras dapat meningkatkan *accuracy* klasifikasi secara signifikan [9]. Namun, mayoritas penelitian tersebut berfokus pada arsitektur *deep learning* dengan *supervised learning* konvensional, bukan pada skenario *few-shot learning*.


Berdasarkan permasalahan tersebut, penelitian ini mengusulkan metode klasifikasi *diabetic retinopathy* menggunakan *prototypical network* yang diperkuat dengan *preprocessing* khusus berupa *modified circle crop* dan *enhanced green channel*. *Modified circle crop* bertujuan untuk mendeteksi dan memotong area lingkaran retina secara otomatis sehingga menghilangkan *background* hitam yang tidak relevan dan memperbesar area retina pada citra. *Enhanced green channel preprocessing* bertujuan untuk meningkatkan kontras lesi mikrovaskuler dengan memanfaatkan fakta bahwa kanal hijau memiliki kontras terbaik untuk memvisualisasikan pembuluh darah dan lesi dibandingkan kanal merah atau biru [10]. Kontribusi utama penelitian ini adalah kombinasi dua teknik *preprocessing* yang saling melengkapi untuk meningkatkan performa *prototypical network* dalam skenario *few-shot learning* pada klasifikasi *diabetic retinopathy*. Tujuan penelitian adalah untuk mengevaluasi pengaruh *preprocessing* gabungan terhadap *accuracy* klasifikasi serta menganalisis peningkatan performa pada setiap tingkat keparahan penyakit.

## 2. METODE PENELITIAN

Pada bagian ini dijelaskan tahapan penelitian yang dilakukan secara sistematis, meliputi deskripsi *dataset* yang digunakan, tahapan *preprocessing* dengan *modified circle crop* dan *enhanced green channel*, arsitektur *prototypical network*, strategi pelatihan dalam *setting few-shot learning*, serta metode evaluasi yang digunakan untuk mengukur kinerja sistem.

### 2.1. Dataset

Penelitian menggunakan *dataset* APTOS 2019 *Blindness Detection* yang berisi 3662 citra fundus retina hasil pemeriksaan klinis pasien diabetes di India dengan kamera fundus berbagai jenis [11]. *dataset* ini memiliki karakteristik kualitas citra yang bervariasi dengan perbedaan pencahayaan, fokus, dan resolusi yang mencerminkan kondisi nyata di fasilitas kesehatan. Citra diklasifikasikan ke dalam lima tingkat keparahan berdasarkan skala *International Clinical Diabetic Retinopathy* (ICDR), yaitu *no DR*, *mild*, *moderate*, *severe*, dan *proliferative*. Distribusi kelas menunjukkan ketidakseimbangan data yang signifikan seperti ditunjukkan pada Gambar 1. *dataset* dibagi menjadi 80% untuk *training* (2929 citra) dan 20% untuk *testing* (733 citra) menggunakan *stratified sampling* untuk mempertahankan proporsi kelas pada setiap *subset* [12]. Pada *subset training*, distribusi kelas dibagi menjadi *no DR* sebanyak 1444 citra, *mild* sebanyak 296 citra, *moderate* sebanyak 799 citra, *severe* sebanyak 154 citra, dan *proliferative* sebanyak 236 citra. *Subset testing* mempertahankan proporsi yang serupa dengan *no DR* sebanyak 361 citra, *mild* sebanyak 74 citra, *moderate* sebanyak 200 citra, *severe* sebanyak 39 citra, dan *proliferative* sebanyak 59 citra. Ketidakseimbangan kelas ini mencerminkan prevalensi alami *diabetic retinopathy* di populasi dimana kasus *no DR* dan *moderate* lebih sering ditemukan dibanding *severe* dan *proliferative* yang merupakan stadium lanjut penyakit.



Gambar 1. Distribusi Kelas pada Subset Training dan Testing Dataset APTOS 2019

## 2.2. Preprocessing

Tahap *preprocessing* terdiri dari dua komponen utama yang dirancang untuk meningkatkan kualitas representasi citra fundus. Pada citra retinal, sebagian area di luar *field of view* umumnya berupa latar belakang hitam yang tidak mengandung informasi diagnostik, sedangkan lesi patologis seperti mikroaneurisma, eksudat, dan pembuluh darah halus sering memiliki kontras rendah. Kondisi ini berpotensi mengganggu proses ekstraksi fitur oleh *convolutional neural network*. Kedua komponen *preprocessing* diimplementasikan secara terintegrasi dalam satu *pipeline* yang diterapkan pada seluruh *dataset* sebelum pelatihan model [13], [14].

### 2.2.1. Modified Circle crop

Komponen pertama adalah *modified circle crop* yang bertujuan untuk mendeteksi area retina berbentuk lingkaran dan menghilangkan *background* hitam tidak relevan. Penghapusan area *non-informatif* terbukti mampu meningkatkan rasio *region of interest* serta mengurangi *noise* spasial sehingga model dapat memfokuskan pembelajaran pada struktur anatomi penting [15], [16]. Algoritma dimulai dengan konversi citra RGB ke *grayscale* untuk menyederhanakan representasi intensitas piksel. Selanjutnya diterapkan *Gaussian blur* dengan kernel 5×5 untuk mengurangi *noise* sebelum proses *thresholding*. Nilai *threshold* ditetapkan sebesar 10 untuk memisahkan area retina yang memiliki intensitas lebih tinggi dari *background* hitam yang mendominasi area di luar *field of view* kamera fundus. Deteksi kontur dilakukan menggunakan fungsi `findContours` dengan mode `RETR_EXTERNAL` untuk menemukan kontur terluar saja, karena area retina diasumsikan sebagai *region* terbesar pada citra. Kontur dengan area terbesar dipilih sebagai representasi area fundus, kemudian dilakukan ekstraksi *bounding box* dengan koordinat  $(x, y, w, h)$  untuk melakukan *cropping*. Hasil *cropping* berupa citra RGB yang hanya berisi area retina tanpa *background* hitam, sehingga memperbesar proporsi *region of interest* dan mengurangi *noise* yang dapat mengganggu pembelajaran *embedding*.

### 2.2.2. Enhanced Green Channel

Komponen kedua adalah *enhanced green channel preprocessing* yang memanfaatkan fakta bahwa kanal hijau (*green channel*) memiliki kontras terbaik untuk menampilkan lesi mikrovaskuler pada citra fundus retina [17]. Metode ini mengadopsi pendekatan yang mengombinasikan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dengan *unsharp masking*. Proses dimulai dengan ekstraksi kanal hijau dari citra RGB hasil *circle crop*. Selanjutnya diterapkan CLAHE untuk meningkatkan kontras lokal dengan parameter *clip limit* 2.0 dan *tile grid size* 8×8. CLAHE membagi citra ke dalam beberapa wilayah kontekstual dan menerapkan histogram *equalization* pada setiap wilayah, sehingga dapat menonjolkan fitur tersembunyi seperti eksudat, mikroaneurisma, fovea, dan pembuluh darah tanpa *over-amplifying noise* pada area yang sudah memiliki kontras tinggi [18], [19].

Setelah kontras diperbaiki dengan CLAHE, dilakukan penajaman citra menggunakan *unsharp masking*. Teknik ini bekerja dengan cara membuat *mask* dari selisih antara citra asli dengan citra yang sudah diburamkan, kemudian menambahkan *mask* tersebut kembali ke citra asli untuk meningkatkan ketajaman tepi [20]. Proses *unsharp masking* terdiri dari tiga tahap. Pertama, citra hasil CLAHE diburamkan menggunakan *Gaussian blur* dengan parameter  $\sigma = 10$ . Kedua, dibentuk *mask* implisit melalui operasi *weighted addition*. Ketiga, citra output dihasilkan dengan menggabungkan citra asli dan citra blur menggunakan koefisien tertentu.

Proses *Gaussian blur* untuk *unsharp masking* dinyatakan dengan persamaan:

$$g(n, m) = G(n, m, \sigma) \otimes x(n, m) \quad (1)$$

dimana  $G(n, m, \sigma)$  adalah *Gaussian filter* dengan  $\sigma = 10$ ,  $x(n, m)$  adalah citra *green channel* hasil CLAHE, dan  $\otimes$  adalah operator konvolusi.

Selanjutnya, *unsharp masking* diterapkan menggunakan persamaan:

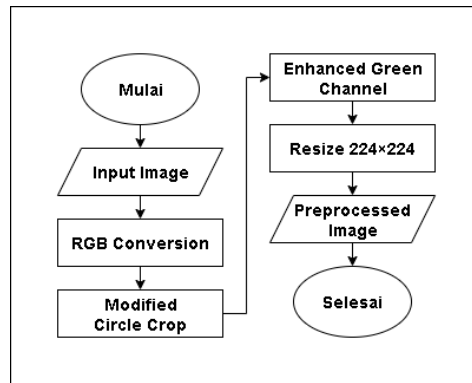
$$y(n, m) = \alpha \times x(n, m) + \beta \times g(n, m) \quad (2)$$

dimana  $\alpha$  adalah koefisien citra asli yang ditetapkan dengan nilai 4, dan  $\beta = 1 - \alpha = -3$ . Nilai  $\alpha$  yang lebih besar dari 1 menghasilkan efek penajaman yang kuat, sementara nilai  $\beta$  negatif berfungsi untuk mengurangi komponen blur sehingga meningkatkan ketajaman tepi objek seperti pembuluh darah dan lesi mikroaneurisma.

Citra hasil *enhanced green channel* kemudian disimpan sebagai citra tiga kanal dengan *channel* yang sama ( $G, G, G$ ), dimana  $G$  adalah hasil dari proses CLAHE dan *unsharp masking*. Representasi tiga kanal ini diperlukan agar kompatibel dengan arsitektur CNN yang mengharapkan input berukuran  $224 \times 224 \times 3$  [17].

### 2.2.3. Pipeline Preprocessing Gabungan

Kedua komponen *preprocessing* diintegrasikan dalam satu *pipeline* terstruktur yang diterapkan secara berurutan. *Pipeline* dimulai dengan *loading* citra dari *storage*, konversi dari format BGR (OpenCV default) ke RGB, aplikasi *circle crop* untuk menghilangkan *background*, aplikasi *enhanced green channel* untuk meningkatkan visibilitas lesi, dan diakhiri dengan *resize* ke ukuran  $224 \times 224$  piksel untuk memenuhi kebutuhan input model. Seluruh citra *training* dan *testing* diproses secara *offline* sebelum pelatihan model untuk menghemat waktu komputasi selama *episodic training* [21]. Hasil *preprocessing* disimpan dalam direktori terpisah dengan format PNG untuk menjaga kualitas citra tanpa *lossy compression*. Gambar 2 menunjukkan diagram alir lengkap dari *pipeline preprocessing* yang diterapkan.



Gambar 2. Diagram Alir Pipeline Preprocessing

### 2.3. Arsitektur Prototypical Network

*Prototypical network* terdiri dari dua komponen utama, yaitu *embedding network* dan *distance-based classifier* [5]. *Embedding network* dirancang menggunakan arsitektur CNN dengan empat blok konvolusi. Setiap blok terdiri dari lapisan konvolusi dengan 64 filter berukuran  $3 \times 3$ , *batch normalization*, fungsi aktivasi ReLU, dan *max pooling*  $2 \times 2$ . Arsitektur ini menghasilkan *embedding* berdimensi 128 untuk setiap citra input. Secara formal, diberikan input *image*  $x \in \mathbb{R}^{224 \times 224 \times 3}$ , *embedding network*  $f_\theta$  memetakan input ke ruang *embedding*:

$$z = f_\theta(x) \in \mathbb{R}^{128} \quad (3)$$

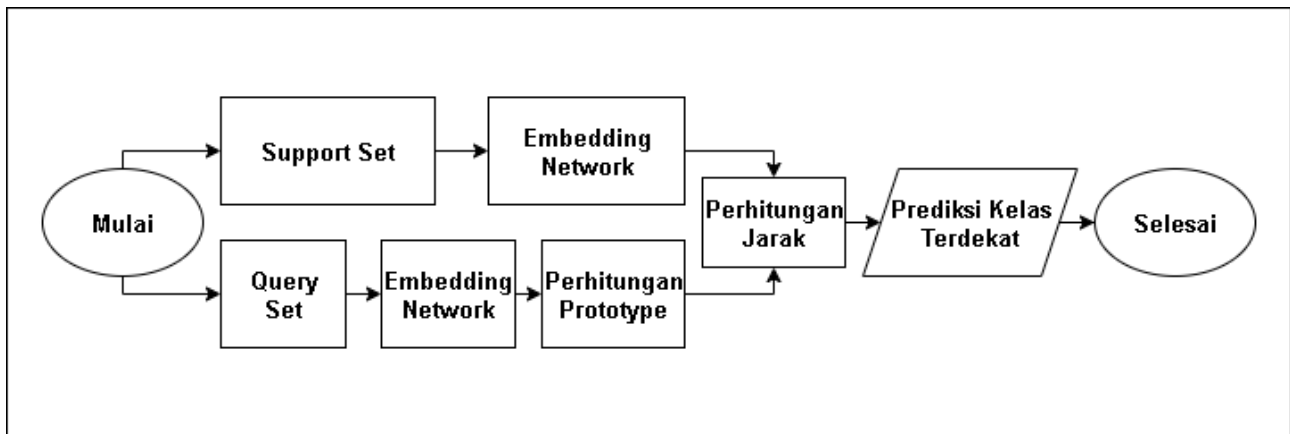
*Prototype* setiap kelas  $c$  dihitung sebagai *centroid* atau *mean embedding* dari semua sampel kelas tersebut dalam *support set*:

$$p_c = \left( \frac{1}{|S_c|} \right) \sum_{(x_i, y_i) \in S_c} f_\theta(x_i) \quad (4)$$

dimana  $S_c$  adalah *support set* untuk kelas  $c$ ,  $|S_c|$  adalah jumlah sampel dalam *support set* tersebut, dan  $(x_i, y_i)$  adalah pasangan citra dan label kelas. Klasifikasi dilakukan dengan menghitung jarak *Euclidean* antara *embedding query* dengan setiap *prototype*, kemudian memilih kelas dengan jarak terdekat:

$$\hat{y} = \operatorname{argmin}_c \|f_\theta(x) - p_c\|_2 \quad (5)$$

dimana  $\hat{y}$  adalah prediksi kelas dan  $\|\cdot\|_2$  adalah norma *Euclidean*. Pendekatan ini memungkinkan model untuk melakukan klasifikasi tanpa perlu melatih *classifier* terpisah, sehingga cocok pada skenario dengan jumlah data terbatas. Gambar 3 menunjukkan arsitektur lengkap *prototypical network* yang digunakan dalam penelitian ini.



Gambar 3. Arsitektur Prototypical Network

#### 2.4. Training Strategy dalam Few-Shot Learning

Training prototypical network dilakukan menggunakan strategi *episodic training* yang mensimulasikan kondisi *few-shot learning* pada setiap iterasi [5]. Setiap episode terdiri dari dua *subset*, yaitu *support set* dan *query set*. Penelitian ini menggunakan konfigurasi *5-way 5-shot*, yang berarti setiap episode melibatkan 5 kelas ( $N = 5$ ) dengan masing-masing kelas memiliki 5 sampel pada *support set* ( $K = 5$ ), sehingga total 25 citra per episode. *Query set* diambil secara acak dari kelas yang sama sebanyak 10 citra per kelas ( $N_{query} = 10$ ), sehingga total 50 *query* per episode. Setiap *epoch* terdiri dari 100 episode *training*. Untuk setiap episode, model menghitung *prototype* berdasarkan *embedding support set*, kemudian mengklasifikasikan *query set* berdasarkan jarak terdekat ke *prototype* masing-masing kelas.


*Loss function* yang digunakan adalah *prototypical loss* yang didefinisikan sebagai *negative log-probability* dari jarak *Euclidean* yang telah dinormalisasi dengan fungsi *softmax* [5]:

$$L = -\log \left( \frac{\exp(-d(f_{\theta}(x), p_y))}{\sum_{c'} \exp(-d(f_{\theta}(x), p_{c'}))} \right) \quad (6)$$

dimana  $y$  adalah *true class* dan  $d$  adalah jarak *Euclidean*. Optimasi dilakukan menggunakan *Adam optimizer* dengan *learning rate*  $1 \times 10^{-4}$  tanpa *weight decay* untuk menjaga kesederhanaan konfigurasi pelatihan [22]. *Training* dilakukan selama maksimal 50 *epochs* dengan mekanisme *early stopping* menggunakan *patience* 10 *epochs*, dimana *training* akan berhenti jika tidak ada peningkatan *validation accuracy* selama 10 *epochs* berturut-turut. *Embedding dimension* ditetapkan sebesar 128 untuk menghasilkan representasi fitur yang cukup diskriminatif namun tetap efisien secara komputasi.

#### 2.5. Alur Keseluruhan Sistem

Sistem klasifikasi *diabetic retinopathy* yang diusulkan mengintegrasikan seluruh komponen *preprocessing* dan *prototypical network* dalam satu alur kerja yang terstruktur. Gambar 4 menunjukkan diagram alir lengkap dari sistem yang dimulai dari input citra fundus hingga hasil klasifikasi tingkat keparahan *diabetic retinopathy*. Proses dimulai dengan tahap *preprocessing* dimana citra fundus asli melalui serangkaian transformasi berupa *circle crop* untuk isolasi *region of interest* dan *enhanced green channel* untuk peningkatan kontras lesi. Citra hasil *preprocessing* kemudian menjadi input untuk *prototypical network* yang melakukan ekstraksi fitur melalui *embedding network* dan klasifikasi berbasis jarak *Euclidean* terhadap *prototype* setiap kelas.



Gambar 4. Diagram Alir Keseluruhan Sistem Klasifikasi

Pada fase *training*, model menerima episode yang terdiri dari *support set* dan *query set* secara berulang. *Support set* digunakan untuk membentuk *prototype* representasi setiap kelas melalui operasi *averaging embedding*, sementara *query set* digunakan untuk menghitung *loss* dan melakukan *backpropagation* untuk optimasi parameter *embedding network*. Proses *episodic training* ini mensimulasikan kondisi *few-shot learning* sehingga model terlatih untuk melakukan klasifikasi dengan jumlah sampel terbatas per kelas. Pada fase *testing*, model menerima citra *query* yang telah di-*preprocessing*, mengekstraksi *embedding*-nya, kemudian mengklasifikasikan berdasarkan jarak terdekat terhadap *prototype* yang telah dipelajari selama *training*. Hasil

klasifikasi berupa prediksi tingkat keparahan *diabetic retinopathy* kemudian dievaluasi menggunakan berbagai metrik untuk mengukur performa sistem secara komprehensif.

### 2.6. Model Baseline

Untuk mengevaluasi kontribusi *preprocessing*, digunakan model *baseline* berupa *Prototypical Network* tanpa tahap *preprocessing* apa pun. Citra input langsung digunakan dari *dataset* asli tanpa *circle crop*, tanpa peningkatan kontras, dan tanpa modifikasi tambahan, selain penyesuaian ukuran ke 224×224 piksel untuk kebutuhan arsitektur. Arsitektur *embedding* dan konfigurasi *episodic training* dibuat identik dengan model usulan. Dengan demikian, perbedaan performa yang diperoleh sepenuhnya merefleksikan dampak penggunaan *preprocessing* terhadap kualitas representasi fitur.

### 2.7. Evaluasi

Evaluasi menggunakan metrik standar klasifikasi yaitu *accuracy*, *precision*, *recall*, dan *F1-score* dengan *macro-averaging*, serta *quadratic weighted kappa* (QWK) untuk mengukur kesesuaian pada klasifikasi ordinal [16]. Uji signifikansi statistik dilakukan menggunakan *paired t-test* dengan *alpha* 0.05 dan *effect size* dihitung menggunakan *Cohen's d* [23].

#### 2.7.1. Metrik Evaluasi

Evaluasi kuantitatif dilakukan menggunakan metrik standar klasifikasi yang meliputi *accuracy*, *precision*, *recall*, dan *F1-score* dengan strategi *macro-averaging* untuk memberikan bobot yang sama pada setiap kelas. Selain metrik standar, digunakan juga *quadratic weighted kappa* (QWK) yang dirancang khusus untuk mengukur kesesuaian pada masalah klasifikasi ordinal dengan memberikan penalti lebih besar pada kesalahan prediksi yang berjauhan secara ordinal [24]. *Quadratic weighted kappa* sangat relevan untuk *diabetic retinopathy* karena tingkat keparahan penyakit memiliki struktur ordinal yang jelas, dimana tingkat keparahan meningkat secara bertahap dari *no DR*, *mild*, *moderate*, *severe*, hingga *proliferative*. Kesalahan prediksi antara kelas yang berdekatan lebih dapat ditoleransi dibandingkan kesalahan yang melompati beberapa tingkat keparahan.

#### 2.7.2. Visualisasi Ruang Embedding dengan t-SNE

Analisis ruang *embedding* dilakukan untuk memahami bagaimana *preprocessing* mempengaruhi pemisahan representasi fitur antar kelas dalam ruang dimensi tinggi. Visualisasi menggunakan metode t-SNE (*t-Distributed Stochastic Neighbor Embedding*) untuk mereduksi *embedding* berdimensi 128 menjadi proyeksi 2 dimensi yang dapat divisualisasikan. Metode t-SNE dipilih karena kemampuannya dalam mempertahankan struktur lokal data sehingga sampel yang mirip dalam ruang dimensi tinggi akan tetap berdekatan dalam proyeksi 2D [25]. Parameter t-SNE yang digunakan meliputi *perplexity* 30 dan 1000 iterasi optimasi. Tujuan visualisasi ini adalah untuk mengobservasi apakah *preprocessing* menghasilkan kluster yang lebih terpisah dan terstruktur sesuai dengan tingkat keparahan penyakit, serta untuk memverifikasi bahwa model membentuk representasi yang mencerminkan struktur ordinal *diabetic retinopathy*.

#### 2.7.3. Interpretabilitas Model dengan Gradient-weighted Class Activation Mapping

Untuk memahami area mana pada citra fundus yang menjadi fokus perhatian model dalam membuat prediksi, dilakukan analisis menggunakan *Gradient-weighted Class Activation Mapping* (Grad-CAM). Teknik ini menghasilkan *heatmap* yang menunjukkan *region* pada citra input yang paling berpengaruh terhadap keputusan klasifikasi model dengan cara menghitung gradien dari skor prediksi kelas terhadap *feature maps* pada layer konvolusi terakhir [26]. Tujuan analisis ini adalah untuk memverifikasi apakah model benar-benar memfokuskan atensi pada area yang relevan secara klinis seperti lokasi lesi mikroaneurisma, eksudat, dan neovaskularisasi, atau justru bergantung pada artefak dan *noise* yang tidak relevan. Grad-CAM memberikan interpretabilitas terhadap keputusan model dan membantu membangun kepercayaan terhadap sistem klasifikasi berbasis *deep learning* dalam aplikasi medis diagnostik.

## 3. HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil eksperimen dari model yang diusulkan beserta analisis perbandingan dengan model *baseline*, analisis performa per kelas untuk memahami dampak ketidakseimbangan data, serta pembahasan kontribusi *preprocessing* terhadap peningkatan *accuracy* klasifikasi dan interpretabilitas model.

### 3.1. Performa Keseluruhan

Tabel 1 menyajikan hasil evaluasi kedua model pada *dataset testing*. Model dengan kombinasi *modified circle crop* dan *enhanced green channel* mencapai *accuracy* 71.35%, melampaui model tanpa *preprocessing* sebesar 64.53% dengan *gain* absolut +6.82%. Nilai *quadratic weighted kappa* juga menunjukkan peningkatan dari 0.5712 menjadi 0.6990, mengindikasikan bahwa model lebih akurat dalam mempertahankan struktur ordinal tingkat keparahan *diabetic retinopathy*. Peningkatan pada metrik *precision macro* (+0.0790) dan *F1-score macro* (+0.0169) menunjukkan bahwa *preprocessing* tidak hanya meningkatkan *accuracy* global tetapi juga memperbaiki performa pada masing-masing kelas.

Tabel 1. Perbandingan Performa Model

No	Model	Accuracy	Precision	Recall	F1-Score	QWK
1	Model Baseline	64.53%	0.4806	0.4784	0.4658	0.5712

2	Model dengan <i>Preprocessing</i>	71.35%	0.5596	0.4757	0.4827	0.6990
<b>Gain Absolut</b>		<b>+6.82%</b>	<b>+0.0790</b>	<b>-0.0027</b>	<b>+0.0169</b>	<b>+0.1278</b>

Hasil ini menunjukkan bahwa *preprocessing* gabungan memberikan dampak signifikan terhadap kemampuan model dalam mengekstraksi fitur diskriminatif dari citra fundus. *Circle crop* menghilangkan *noise background* yang dapat mengacaukan pembelajaran *embedding*, sementara *enhanced green channel* memperkuat visibilitas lesi mikrovaskuler yang menjadi penanda utama tingkat keparahan *diabetic retinopathy*. Kombinasi kedua komponen bekerja secara sinergis yang dimana area retina yang sudah di-*crop* memberikan *region of interest* yang lebih fokus, dan *enhanced green channel* memaksimalkan informasi kontras lesi pada area tersebut.

### 3.2. Analisis Per Kelas

Tabel 2 menyajikan perbandingan *accuracy* per kelas antara model tanpa *preprocessing* dan model dengan kombinasi *preprocessing*. Peningkatan terbesar terjadi pada kelas *moderate* (+9.50%) dan *proliferative* (+7.63%), dimana kedua kelas ini memiliki karakteristik lesi yang lebih kompleks dan memerlukan visibilitas tinggi untuk deteksi yang akurat. Kelas *no DR* mengalami penurunan kecil (-1.94%) yang masih dalam batas toleransi, kemungkinan disebabkan oleh transformasi *preprocessing* yang meningkatkan kontras sehingga beberapa sampel *borderline* keliru diprediksi sebagai *mild*. Kelas *mild* mengalami peningkatan moderat (+4.05%), menunjukkan bahwa *enhanced green channel* membantu mendeteksi lesi awal yang tipis seperti mikroaneurisma kecil.

Tabel 2. Perbandingan *Accuracy* Per Kelas

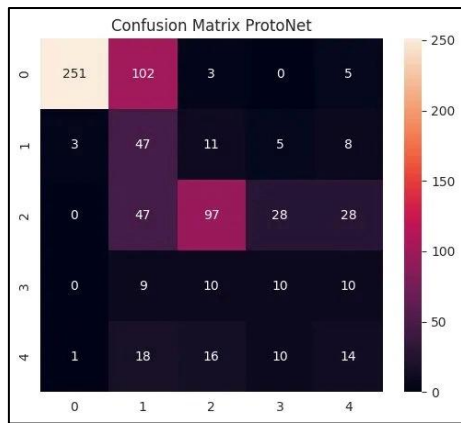
No	Kelas	Support	Baseline (%)	Model <i>Preprocessing</i> (%)	Δ (%)
1	<i>No DR</i>	361	92.24	90.30	-1.94
2	<i>Mild</i>	74	47.30	51.35	+4.05
3	<i>Moderate</i>	200	71.50	81.00	+9.50
4	<i>Severe</i>	39	28.21	30.77	+2.56
5	<i>Proliferative</i>	59	47.46	55.09	+7.63

Kelas *severe* memiliki performa terendah dengan *accuracy* hanya 30.77%, yang dapat dijelaskan oleh dua faktor. Pertama, jumlah sampel kelas *severe* sangat terbatas (39 citra) sehingga *prototype* yang terbentuk kurang representatif. Kedua, karakteristik visual kelas *severe* memiliki *overlap* yang tinggi dengan kelas *moderate* dan *proliferative*, menyebabkan ambiguitas dalam klasifikasi berbasis jarak. Meskipun demikian, model menunjukkan peningkatan +2.56% dibanding *baseline*, mengindikasikan bahwa *preprocessing* tetap memberikan dampak positif meskipun pada kelas minoritas.

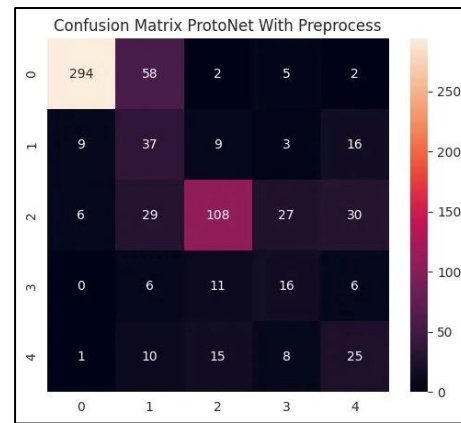
Pola peningkatan performa yang tidak merata pada setiap kelas mencerminkan karakteristik visual yang berbeda-beda. Kelas dengan lesi yang jelas dan kontras tinggi (*moderate* dan *proliferative*) mendapatkan manfaat lebih besar dari *enhanced green channel* karena lesi seperti *hard exudates*, *cotton wool spots*, dan *neovascularization* menjadi lebih terlihat pada kanal hijau yang ditingkatkan. Sebaliknya, kelas *no DR* yang tidak memiliki lesi patologis justru sedikit menurun karena *enhancement* dapat membuat *normal variations* pada retina terlihat seperti lesi ringan.

### 3.3. Analisis *Confusion Matrix*

Analisis *confusion matrix* memberikan gambaran pola kesalahan prediksi model pada setiap kelas *diabetic retinopathy* sebelum dan sesudah *preprocessing*, sebagaimana ditunjukkan pada Gambar 5 dan Gambar 6. Pada model *baseline* tanpa *preprocessing* (Gambar 5), kesalahan prediksi tersebar luas dengan *overlap* tinggi antar kelas berdekatan, khususnya pada kelas *mild*, *moderate*, *severe*, dan *proliferative*. Kelas *no DR* (kelas 0) hanya menghasilkan 251 prediksi benar dari 361 sampel dengan kesalahan dominan ke kelas *mild*, sementara kelas *mild* menunjukkan performa terendah dengan hanya 47 prediksi benar dari 74 sampel. Kelas *moderate*, *severe*, dan *proliferative* juga mengalami misklasifikasi signifikan ke kelas berdekatan, menandakan kesulitan model dalam membedakan tingkat keparahan ketika citra mengandung *noise* dan kontras rendah.



Gambar 5. Confusion Matrix Model Tanpa Preprocessing




Gambar 6. Confusion Matrix Model dengan Preprocessing

Setelah penerapan *preprocessing* (Gambar 6), terlihat peningkatan yang konsisten pada nilai *diagonal matrix* yang menunjukkan prediksi benar, khususnya pada kelas *no DR*, *moderate*, *severe*, dan *proliferative*, disertai dengan penurunan kesalahan lintas kelas yang berjauhan. Pola misklasifikasi yang tersisa sebagian besar terjadi pada kelas yang berdekatan secara ordinal, mencerminkan kemampuan model dalam memahami struktur progresif *diabetic retinopathy*, yang juga diperkuat oleh nilai *Quadratic Weighted Kappa* (QWK) sebesar 0.6990. Temuan ini mengindikasikan bahwa *preprocessing* efektif dalam memperjelas karakteristik visual tiap tingkat keparahan dan mengurangi kesalahan prediksi yang tidak relevan secara klinis.

### 3.4 Visualisasi Dampak *Preprocessing* pada Representasi Citra dan Area Atensi Model

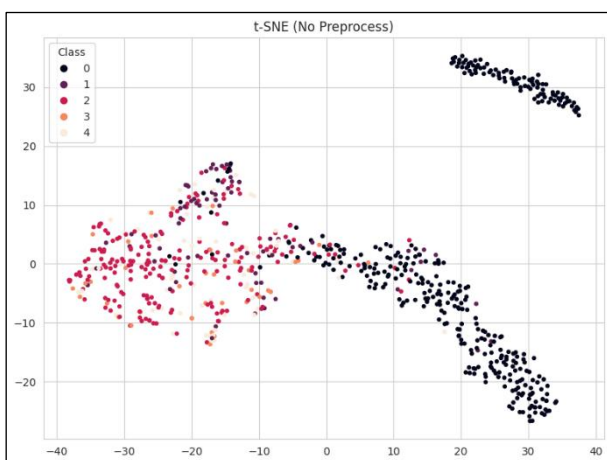
Untuk memahami dampak *preprocessing* terhadap fokus atensi model dan kualitas representasi citra fundus, dilakukan analisis visual menggunakan Grad-CAM sebagaimana ditampilkan pada Gambar 7. Pada citra tanpa *preprocessing*, model cenderung memberikan atensi yang tersebar dan tidak relevan secara klinis, terutama pada area *boundary* antara retina dan *background* hitam, yang menunjukkan bahwa *noise* spasial mengganggu proses ekstraksi fitur. Area internal retina yang seharusnya menjadi fokus diagnostik justru menerima atensi yang lebih rendah. Sebaliknya, pada citra hasil *preprocessing* yang menerapkan *modified circle crop* dan *enhanced green channel*, *background non-relevant* berhasil dieliminasi dan kontras struktur internal retina meningkat secara signifikan. *Heatmap* Grad-CAM pada kondisi ini menunjukkan atensi tinggi yang terfokus pada struktur anatomis penting seperti pembuluh darah retina dan *optic disc*, yang merupakan *landmark* utama dalam diagnosis *diabetic retinopathy*. Pola atensi yang lebih terarah ini tidak hanya terlihat pada kelas *no DR*, tetapi juga konsisten pada kelas dengan patologi, dimana model mampu memusatkan perhatian pada lokasi lesi seperti mikroaneurisma, eksudat, dan neovaskularisasi. Hasil ini mengonfirmasi bahwa *preprocessing* berperan penting dalam membantu model mengekstraksi fitur dari area yang relevan secara diagnostik.




Gambar 7. Visualisasi Perbandingan Input dan Heatmap Atensi Model

### 3.5 Analisis Struktur Ruang *Embedding*

Visualisasi t-SNE pada ruang *embedding* model *baseline* dan model dengan *preprocessing*, sebagaimana ditunjukkan pada Gambar 8 dan Gambar 9, memperlihatkan perbedaan signifikan dalam kualitas pemisahan kluster antar kelas. Pada model *baseline* tanpa *preprocessing*, kelas *no DR* membentuk dua kluster terpisah yang relatif padat, sementara kelas-kelas dengan patologi menunjukkan *overlap* yang sangat tinggi dan membentuk satu *region* bercampur tanpa batas yang jelas, mengindikasikan lemahnya representasi diskriminatif akibat *noise* dan rendahnya kontras lesi. Sebaliknya, model dengan *preprocessing* menunjukkan pemisahan kluster yang lebih terstruktur dan jelas, khususnya pada kelas-kelas dengan patologi, meskipun *overlap* antar kelas berdekatan masih terjadi secara wajar mengingat sifat progresif *diabetic retinopathy*. Kelas *proliferative* mulai membentuk *region* yang lebih distingtif, mencerminkan keberadaan *marker* visual yang unik seperti neovaskularisasi. Selain itu, distribusi kluster menunjukkan transisi bertahap antar tingkat keparahan, dimana kelas yang berdekatan secara ordinal memiliki jarak *embedding* yang lebih dekat dibanding kelas yang berjauhan. Pola ini menegaskan bahwa *preprocessing* berkontribusi pada pembentukan ruang *embedding* yang lebih informatif dan selaras dengan pengetahuan klinis mengenai progresivitas *diabetic retinopathy*.



Gambar 8. Proyeksi t-SNE Ruang *Embedding* Model Tanpa *Preprocessing*



Gambar 9. Proyeksi t-SNE Ruang *Embedding* Model dengan *Preprocessing*

### 3.6. Diskusi

Hasil eksperimen menunjukkan bahwa *preprocessing* gabungan berupa *modified circle crop* dan *enhanced green channel* terbukti efektif meningkatkan performa *prototypical network* pada klasifikasi *diabetic retinopathy* dengan gain *accuracy* +6.82% dan peningkatan QWK dari 0.5712 menjadi 0.6990. Peningkatan ini signifikan mengingat model beroperasi dalam *setting few-shot learning* dengan hanya 5 sampel per kelas dalam *support set*. Kontribusi *preprocessing* terletak pada dua aspek sinergis, yaitu *circle crop* mengeliminasi *noise background* yang dapat mendistorsi ruang *embedding*, dan *enhanced green channel* meningkatkan *signal-to-noise ratio* dari lesi mikrovaskuler. Peningkatan performa tidak merata pada semua kelas, dimana kelas dengan karakteristik lesi kompleks seperti *moderate* (+9.50%) dan *proliferative* (+7.63%) mengalami peningkatan signifikan, sementara kelas minoritas *severe* tetap menjadi tantangan akibat keterbatasan sampel (39 citra) dan *overlap* visual tinggi dengan kelas *moderate* dan *proliferative*. Nilai QWK yang tinggi mengindikasikan bahwa model mampu mempertahankan struktur ordinal dengan baik, dimana kesalahan prediksi cenderung terjadi pada kelas berdekatan yang lebih dapat ditoleransi secara klinis. Analisis visualisasi Grad-CAM mengonfirmasi bahwa *preprocessing* mengubah fokus atensi model dari *boundary* eksternal yang tidak relevan menjadi struktur internal retina seperti pembuluh darah dan lokasi lesi, sementara proyeksi t-SNE menunjukkan pembentukan kluster yang lebih terpisah dan terstruktur sesuai progresivitas ordinal penyakit.

Keterbatasan penelitian mencakup beberapa aspek yang perlu diperhatikan untuk pengembangan selanjutnya. Eksperimen hanya dilakukan pada satu *dataset* yaitu APTOS 2019 tanpa validasi eksternal pada *dataset* lain yang dapat mengukur kemampuan generalisasi model pada kondisi berbeda. Arsitektur *embedding network* yang digunakan masih sederhana dengan empat blok CNN berisi 64 filter dan berpotensi ditingkatkan dengan arsitektur yang lebih dalam atau memanfaatkan *pre-trained models*. Belum ada evaluasi klinis yang melibatkan *ophthalmologist* untuk memvalidasi relevansi medis dari prediksi model dalam konteks praktik diagnostik sebenarnya. *Preprocessing* juga belum dioptimalkan secara otomatis dimana parameter seperti *clip limit* CLAHE, *sigma Gaussian blur*, dan koefisien *unsharp masking* masih ditentukan secara manual berdasarkan literatur tanpa proses *tuning* sistematis. Penelitian selanjutnya disarankan untuk melakukan validasi eksternal pada *multiple datasets* guna mengukur generalisasi model lintas populasi dan kondisi akuisisi citra yang berbeda. Eksplorasi kombinasi *preprocessing* dengan *transfer learning* menggunakan *pre-trained models* dapat meningkatkan kapasitas model dalam mengekstraksi fitur yang lebih kompleks. Penerapan teknik *handling class imbalance* seperti *focal loss* atau *class-balanced sampling* dapat membantu meningkatkan performa pada kelas minoritas terutama kelas *severe* yang masih memiliki *accuracy* rendah.

## 4. KESIMPULAN

Penelitian ini mengusulkan metode klasifikasi *diabetic retinopathy* menggunakan *prototypical network* yang ditambahkan dengan *preprocessing modified circle crop* dan *enhanced green channel* untuk meningkatkan performa pada skenario *few-shot learning*. Berdasarkan eksperimen pada *dataset* APTOS 2019 dengan 3662 citra fundus retina yang terdistribusi tidak seimbang antar kelas, metode yang diusulkan mencapai *accuracy* 71.35% dan *quadratic weighted kappa* 0.6990, melampaui *baseline* tanpa *preprocessing* dengan *accuracy* 64.53% dan QWK 0.5712, menghasilkan gain absolut +6.82%. Peningkatan signifikan terjadi pada kelas *moderate* (+9.50%) dan *proliferative* (+7.63%) yang memiliki karakteristik lesi kompleks, sementara nilai QWK tinggi menunjukkan model mampu mempertahankan struktur ordinal dengan kesalahan prediksi cenderung terjadi pada kelas berdekatan. Analisis *confusion matrix* mengonfirmasi bahwa misklasifikasi jarang terjadi lintas kategori berjauhan, visualisasi Grad-CAM membuktikan bahwa *preprocessing* mengubah fokus atensi model dari *boundary* eksternal tidak relevan menjadi struktur internal retina seperti pembuluh darah dan lokasi lesi, dan proyeksi t-SNE menunjukkan pembentukan kluster yang lebih terpisah dengan transisi bertahap mencerminkan progresivitas ordinal penyakit. Temuan ini menunjukkan bahwa *preprocessing* yang dirancang khusus untuk karakteristik citra fundus dapat meningkatkan performa *prototypical network* secara signifikan pada skenario data terbatas, memberikan kontribusi pada tahap *preprocessing* yang dapat dikombinasikan dengan berbagai arsitektur *deep learning* lainnya untuk aplikasi klasifikasi citra medis, dengan bukti empiris bahwa peningkatan *accuracy* berasal dari perbaikan fundamental dalam cara model memproses dan merepresentasikan informasi visual dari citra fundus retina.

## DAFTAR PUSTAKA

- [1] R. Singh, A. Walia, J. Kaur, P. Kumar, I. Verma, and N. Rani, "Diabetic Retinopathy - Pathophysiology to Treatment: A Review," *Curr. Diabetes Rev.*, vol. 21, no. 3, Mar. 2025, doi: 10.2174/0115733998259940231105200251.
- [2] M. Kropp *et al.*, "Diabetic retinopathy as the leading cause of blindness and early predictor of cascading complications—risks and mitigation," *EPMA Journal*, vol. 14, no. 1, pp. 21–42, Feb. 2023, doi: 10.1007/s13167-023-00314-8.
- [3] A. Rahimah, A. C. Siregar, and M. W. Pangestika, "Prediction of Diabetes Mellitus Using the Case-Based Reasoning Method," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 3, pp. 516–522, Dec. 2025, doi: 10.37859/coscitech.v6i3.10266.
- [4] C. Mohanty *et al.*, "Using Deep Learning Architectures for Detection and Classification of Diabetic Retinopathy," *Sensors*, vol. 23, no. 12, p. 5726, Jun. 2023, doi: 10.3390/s23125726.
- [5] J. Snell, K. Swersky, and R. S. Zemel, "Prototypical Networks for Few-shot Learning," Jun. 2017, [Online]. Available: <http://arxiv.org/abs/1703.05175>
- [6] A. Ouahab and O. Ben Ahmed, "ProtoMed: Prototypical networks with auxiliary regularization for few-shot medical image classification," *Image Vis. Comput.*, vol. 154, p. 105337, Feb. 2025, doi: 10.1016/j.imavis.2024.105337.
- [7] H. Quan, X. Li, D. Hu, T. Nan, and X. Cui, "Dual-Channel Prototype Network for Few-Shot Pathology Image Classification," *IEEE J. Biomed. Health Inform.*, vol. 28, no. 7, pp. 4132–4144, Jul. 2024, doi: 10.1109/JBHI.2024.3386197.
- [8] C. Suedumrong, S. Phongmoo, T. Akarajaka, and K. Leksakul, "Diabetic Retinopathy Detection Using Convolutional Neural Networks with Background Removal, and Data Augmentation," *Applied Sciences*, vol. 14, no. 19, p. 8823, Sep. 2024, doi: 10.3390/app14198823.

- [9] L. Arora *et al.*, "Ensemble deep learning and EfficientNet for accurate diagnosis of diabetic retinopathy," *Sci. Rep.*, vol. 14, no. 1, p. 30554, Dec. 2024, doi: 10.1038/s41598-024-81132-4.
- [10] M. Sushith, A. Sathya, V. Kalaipoonguzhali, and V. Sathya, "A hybrid deep learning framework for early detection of diabetic retinopathy using retinal fundus images," *Sci. Rep.*, vol. 15, no. 1, p. 15166, Apr. 2025, doi: 10.1038/s41598-025-99309-w.
- [11] S. Karthik; Maggie; Dane, "APTOS 2019 Blindness Detection," Kaggle. Accessed: Oct. 21, 2025. [Online]. Available: <https://www.kaggle.com/competitions/aptos2019-blindness-detection>
- [12] V. Singh, M. Pencina, A. J. Einstein, J. X. Liang, D. S. Berman, and P. Slomka, "Impact of train/test sample regimen on performance estimate stability of machine learning in cardiovascular imaging," *Sci. Rep.*, vol. 11, no. 1, p. 14490, Jul. 2021, doi: 10.1038/s41598-021-93651-5.
- [13] R. Sarki, K. Ahmed, H. Wang, Y. Zhang, J. Ma, and K. Wang, "Image Preprocessing in Classification and Identification of Diabetic Eye Diseases," *Data Sci. Eng.*, vol. 6, no. 4, pp. 455–471, Dec. 2021, doi: 10.1007/s41019-021-00167-z.
- [14] T. B. Nguyen-Tat, T. Q. Hung, P. T. Nam, and V. M. Ngo, "Evaluating pre-processing and deep learning methods in medical imaging: Combined effectiveness across multiple modalities," *Alexandria Engineering Journal*, vol. 119, pp. 558–586, Apr. 2025, doi: 10.1016/j.aej.2025.01.090.
- [15] A.-O. Asia *et al.*, "Detection of Diabetic Retinopathy in Retinal Fundus Images Using CNN Classification Models," *Electronics (Basel)*, vol. 11, no. 17, p. 2740, Aug. 2022, doi: 10.3390/electronics11172740.
- [16] K. Oh, H. M. Kang, D. Leem, H. Lee, K. Y. Seo, and S. Yoon, "Early detection of diabetic retinopathy based on deep learning and ultra-wide-field fundus images," *Sci. Rep.*, vol. 11, no. 1, p. 1897, Jan. 2021, doi: 10.1038/s41598-021-81539-3.
- [17] J. E. Widayana and S. Budi, "Pengaruh Preprocessing Terhadap Klasifikasi Diabetic Retinopathy dengan Pendekatan Transfer Learning Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 1, Apr. 2021, doi: 10.28932/jutisi.v7i1.3327.
- [18] M. Hayati *et al.*, "Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning," *Procedia Comput. Sci.*, vol. 216, pp. 57–66, 2023, doi: 10.1016/j.procs.2022.12.111.
- [19] S. Rasta, M. Partovi, H. Seyedarabi, and A. Javadzadeh, "A comparative study on preprocessing techniques in diabetic retinopathy retinal images: Illumination correction and contrast enhancement," *J. Med. Signals Sens.*, vol. 5, no. 1, p. 40, 2015, doi: 10.4103/2228-7477.150414.
- [20] P. Macsik, J. Pavlovicova, S. Kajan, J. Goga, and V. Kurilova, "Image preprocessing-based ensemble deep learning classification of diabetic retinopathy," *IET Image Process.*, vol. 18, no. 3, pp. 807–828, Feb. 2024, doi: 10.1049/ipr.2.12987.
- [21] S. Masoudi *et al.*, "Quick guide on radiology image pre-processing for deep learning applications in prostate cancer research," *Journal of Medical Imaging*, vol. 8, no. 01, Jan. 2021, doi: 10.1117/1.JMI.8.1.010901.
- [22] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Jan. 2017, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [23] D. Lakens, "Calculating and reporting effect sizes to facilitate cumulative science: a practical primer for t-tests and ANOVAs," *Front. Psychol.*, vol. 4, 2013, doi: 10.3389/fpsyg.2013.00863.
- [24] M. J. Warrens, A. de Raadt, R. J. Bosker, and H. A. L. Kiers, "Weighted Kappa for Interobserver Agreement and Missing Data," *Mach. Learn. Knowl. Extr.*, vol. 7, no. 1, p. 18, Feb. 2025, doi: 10.3390/make7010018.
- [25] M. C. Cieslak, A. M. Castelfranco, V. Roncalli, P. H. Lenz, and D. K. Hartline, "t-Distributed Stochastic Neighbor Embedding (t-SNE): A tool for ecophysiological transcriptomic analysis," *Mar. Genomics*, vol. 51, p. 100723, Jun. 2020, doi: 10.1016/j.margen.2019.100723.
- [26] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization," in *2017 IEEE International Conference on Computer Vision (ICCV)*, IEEE, Oct. 2017, pp. 618–626. doi: 10.1109/ICCV.2017.74.