

## Perbandingan *efficientnet-B0* Pretrained dan Prototypical Network from Scratch untuk Klasifikasi Diabetic Retinopathy

Abi Eka Putra Wulyono\*, Faisal Muttaqin, Budi Mukhamad Mulyo

Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jawa Timur

\*Email: 22081010190@student.upnjatim.ac.id\*, faisalmuttaqin.if@upnjatim.ac.id,

budi.m.mulyo.fasilkom@upnjatim.ac.id

### Abstrak

Penelitian ini membahas perbandingan kinerja model *deep learning* berbasis *transfer learning* dan model yang dilatih dari awal dalam klasifikasi *Diabetic Retinopathy* menggunakan citra fundus retina. Permasalahan utama dalam pengembangan sistem klasifikasi citra medis adalah keterbatasan data berlabel yang dapat memengaruhi kemampuan generalisasi model. Penelitian ini bertujuan menganalisis efektivitas *EfficientNet-B0 pretrained* dibandingkan dengan *Prototypical Network from scratch* pada dataset APTOS 2019 yang terdiri dari 3.662 citra fundus retina dengan lima tingkat keparahan dan distribusi kelas tidak seimbang. Metode penelitian meliputi *preprocessing* berupa penyesuaian ukuran citra menjadi  $224 \times 224$  piksel dan normalisasi nilai piksel. *EfficientNet-B0* menggunakan bobot *pretrained ImageNet* dengan proses *fine tuning*, sedangkan *Prototypical Network* dilatih sepenuhnya dari awal menggunakan pendekatan pembelajaran berbasis metrik. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *Quadratic Weighted Kappa*. Hasil penelitian menunjukkan *EfficientNet-B0 pretrained* memperoleh *accuracy* 80,35 persen, *precision* 0,6587, *recall* 0,6279, *F1-score* 0,6396, dan QWK 0,8529. Sementara itu, *Prototypical Network from scratch* mencapai *accuracy* 64,53 persen, *precision* 0,4806, *recall* 0,4784, *F1-score* 0,4658, dan QWK 0,5712. Perbedaan performa sebesar 15,82 persen pada *accuracy* dan 0,2817 pada QWK menunjukkan bahwa *transfer learning* memberikan hasil yang lebih optimal dibandingkan pelatihan dari awal. Berdasarkan hasil tersebut, penggunaan model *pretrained* terbukti efektif untuk klasifikasi *Diabetic Retinopathy* pada kondisi keterbatasan data dan direkomendasikan dalam pengembangan sistem *Computer Aided Diagnosis*.

**Kata Kunci:** citra medis; *diabetic retinopathy*; *efficientnet*; *prototypical network*; *transfer learning*.

### Comparison of Pretrained *EfficientNet-B0* and From Scratch Prototypical Network for Diabetic Retinopathy Classification

#### Abstract

This study compares the performance of transfer learning based deep learning models and models trained from scratch for Diabetic Retinopathy classification using retinal fundus images. A major challenge in medical image classification is the limited availability of labeled data, which affects model generalization. This research aims to analyze the effectiveness of pretrained *EfficientNet-B0* compared with a from scratch *Prototypical Network* using the APTOS 2019 dataset consisting of 3,662 retinal fundus images with five severity levels and an imbalanced class distribution. The research method includes image preprocessing through resizing to  $224 \times 224$  pixels and pixel normalization. *EfficientNet-B0* utilizes *ImageNet* pretrained weights with fine tuning, while the *Prototypical Network* is trained entirely from scratch using a metric-based learning approach. Model performance is evaluated using *accuracy*, *precision*, *recall*, *F1-score*, and *Quadratic Weighted Kappa*. The results show that pretrained *EfficientNet-B0* achieves 80.35 percent accuracy, 0.6587 precision, 0.6279 recall, 0.6396 *F1-score*, and 0.8529 QWK. In contrast, the from scratch *Prototypical Network* achieves 64.53 percent accuracy, 0.4806 precision, 0.4784 recall, 0.4658 *F1-score*, and 0.5712 QWK. The performance gap of 15.82 percent in accuracy and 0.2817 in QWK indicates that transfer learning provides more optimal results than training from scratch. Therefore, pretrained models are proven to be effective for Diabetic Retinopathy classification under limited data conditions and are recommended for developing *Computer Aided Diagnosis* systems.

**Keywords:** *diabetic retinopathy*; *efficientnet*; medical imaging; *prototypical network*; *transfer learning*

## 1. Pendahuluan

*Diabetic Retinopathy* merupakan komplikasi mikrovaskular dari diabetes mellitus yang menjadi salah satu penyebab utama kebutaan di dunia dan memerlukan deteksi dini untuk mencegah kehilangan penglihatan permanen (Chong et al., 2024; Kropp et al., 2023; Teo et al., 2021). Analisis citra fundus retina secara manual oleh *ophthalmologist* memerlukan waktu lama dan rentan terhadap variabilitas antar pemeriksa, sehingga mendorong kebutuhan solusi otomatis berbasis komputer (Srinivasan et al., 2023).

*Deep learning* khususnya *Convolutional Neural Networks* telah menjadi pendekatan utama dalam klasifikasi citra karena kemampuannya mengekstraksi fitur kompleks tanpa perlu perancangan fitur manual (Kadhim et al., 2022; Zhou et al., 2021). Meskipun demikian, model *deep learning* yang dibangun dari awal (*training from scratch*) seringkali mengalami keterbatasan performa ketika jumlah data berlabel terbatas, karena model cenderung mudah terjadi *overfitting* dan kurang mampu menggeneralisasi pola baru (Hellin et al., 2024).

Untuk mengatasi keterbatasan data ini, *transfer learning* menjadi strategi yang populer dengan memanfaatkan bobot *pretrained* dari *dataset* besar seperti *ImageNet* dan melakukan *fine tuning* pada domain target (Gu & Lee, 2024; Widyaya & Budi, 2021). Pendekatan *transfer learning* telah terbukti meningkatkan performa model pada banyak tugas *medical imaging* dibandingkan dengan pelatihan dari awal dengan data yang sama (Ahmed, 2025).

Model *pretrained* seperti *EfficientNet-B0* dapat memanfaatkan representasi fitur yang telah dipelajari pada *dataset* besar sehingga mempercepat konvergensi dan memperbaiki kemampuan generalisasi pada *dataset* target yang lebih kecil (Arora et al., 2024; Tan & Le, 2020). Di sisi lain, pendekatan *few shot learning* seperti *Prototypical Network* yang dilatih dari awal mencoba menangani skenario dengan sedikit sampel per kelas melalui pembelajaran metrik, namun seringkali tetap kurang optimal pada *dataset* nyata yang tidak seimbang (Liu et al., 2024; Ouahab & Ahmed, 2025; Snell et al., 2017).

Dengan latar belakang tersebut, penelitian ini membandingkan performa *EfficientNet-B0 pretrained* dan *Prototypical Network from scratch* pada klasifikasi *Diabetic Retinopathy* dengan tujuan memberikan bukti empiris efektivitas *transfer learning* pada *dataset* terbatas dan rekomendasi praktis untuk pengembangan sistem *Computer Aided Diagnosis* berbasis *deep learning* (Pachetti & Colantonio, 2024).

## 2. Metode

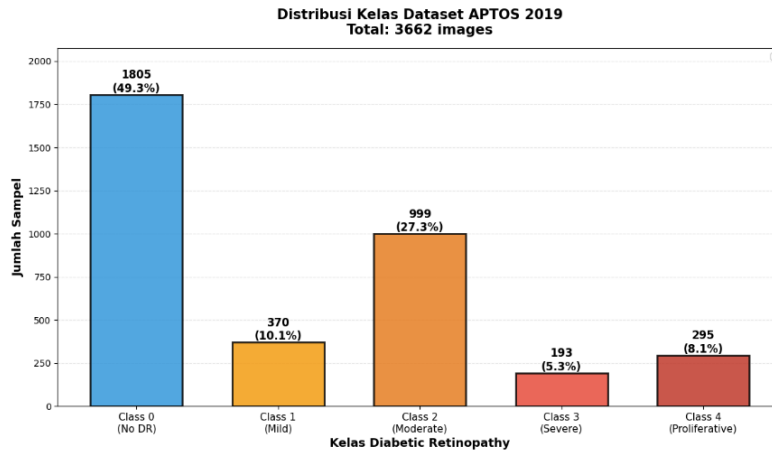
Pada bagian ini dijelaskan metode penelitian yang digunakan, meliputi *dataset* yang digunakan, tahapan *preprocessing* data, arsitektur model yang diterapkan, prosedur pelatihan, serta metode evaluasi untuk membandingkan kinerja *EfficientNet-B0 pretrained* dan *Prototypical Network from scratch*.

### 2.1. Dataset

Penelitian ini menggunakan *dataset* APTOS 2019 *Blindness Detection* yang dipublikasikan oleh *Asia Pacific Tele Ophthalmology Society* (Karthik; Maggie; Dane, 2019). *Dataset* ini berisi 3.662 citra fundus retina dengan resolusi yang bervariasi dan telah diberi label oleh *ophthalmologist* bersertifikat. Contoh citra fundus retina yang digunakan dalam penelitian ini ditunjukkan pada Gambar 1. Setiap citra diklasifikasikan ke dalam lima tingkat keparahan *Diabetic Retinopathy* berdasarkan standar *International Clinical Diabetic Retinopathy* (ICDR), yaitu kelas 0 (*No DR*), kelas 1 (*Mild*), kelas 2 (*Moderate*), kelas 3 (*Severe*), dan kelas 4 (*Proliferative DR*). *Dataset* dibagi menjadi data latih sebesar 80 persen (2.929 citra) dan data uji sebesar 20 persen (733 citra) menggunakan metode *stratified splitting* untuk menjaga proporsi distribusi kelas. Berdasarkan hasil pembagian data, *dataset* menunjukkan kondisi tidak seimbang (*imbalanced*), di mana kelas *No DR* menjadi kelas mayoritas dan kelas *Severe DR* menjadi kelas minoritas. Distribusi jumlah data pada setiap kelas *Diabetic Retinopathy* dapat dilihat pada Gambar 2.



Gambar 1. Contoh Gambar Tiap Kelas



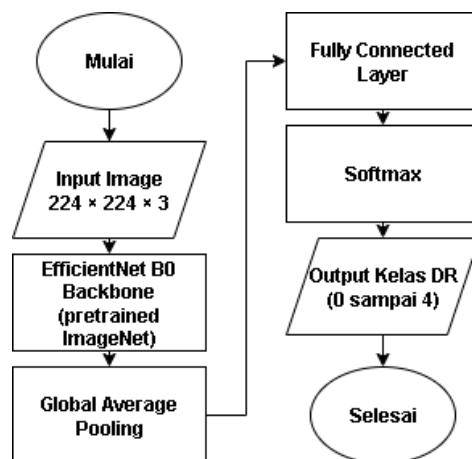
Gambar 2. Distribusi Kelas

## 2.2. Preprocessing

Seluruh citra fundus retina diubah ukurannya menjadi  $224 \times 224$  piksel agar sesuai dengan kebutuhan input kedua model yang digunakan. Selanjutnya dilakukan proses normalisasi nilai piksel dengan membagi nilai RGB dengan 255 sehingga berada pada rentang 0 sampai 1. Pada penelitian ini tidak diterapkan *preprocessing* tambahan seperti *oversampling*, *undersampling* atau *color enhancement*. Hal ini bertujuan untuk menjaga konsistensi evaluasi antara kedua model serta mengamati performa model pada kondisi *preprocessing* standar.

## 2.3. Model 1 EfficientNet-B0 Pretrained

*EfficientNet-B0* merupakan arsitektur *Convolutional Neural Network* yang diperkenalkan oleh Tan dan Le dengan pendekatan *compound scaling*, yaitu penyesuaian kedalaman, lebar, dan resolusi jaringan secara seimbang (Tan & Le, 2020). Pada penelitian ini digunakan *EfficientNet-B0 pretrained ImageNet* sebagai *feature extractor*. Struktur lengkap arsitektur *EfficientNet-B0* yang digunakan ditampilkan pada Gambar 3.

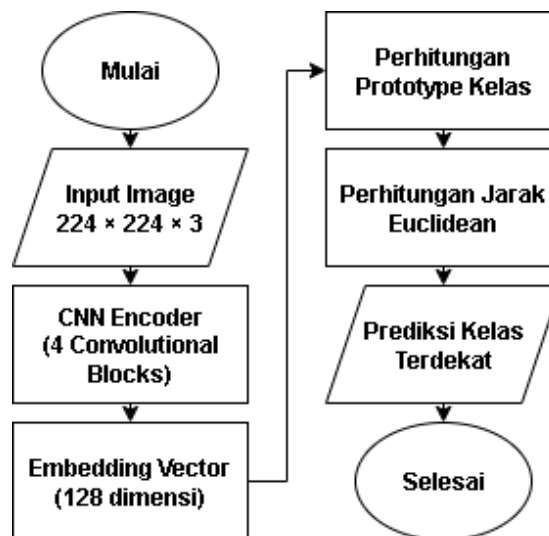


Gambar 3. Arsitektur *EfficientNet-B0 Pretrained*

Bobot awal model berasal dari hasil pelatihan pada *dataset ImageNet*. Layer klasifikasi bawaan model yang memiliki 1000 neuron diganti dengan *layer* baru yang memiliki 5 neuron *output* sesuai jumlah kelas *Diabetic Retinopathy*. Proses *fine tuning* dilakukan pada seluruh *layer* model dengan *learning rate* sebesar  $1 \times 10^{-4}$ . Fungsi *loss* yang digunakan adalah *Categorical Cross Entropy*, sedangkan *optimizer* yang digunakan adalah Adam.

#### 2.4. Model 2 Prototypical Network From Scratch

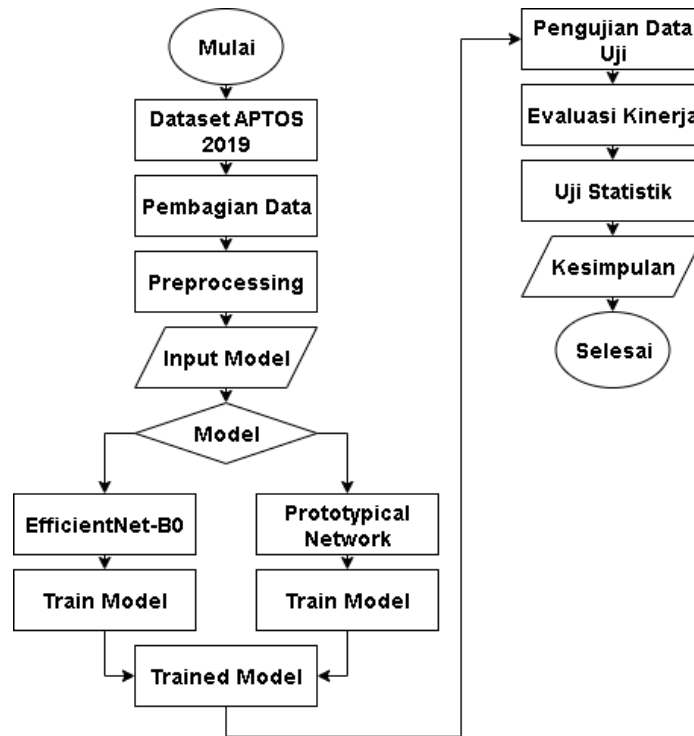
*Prototypical Network* merupakan metode *few shot learning* berbasis *metric learning* yang diperkenalkan oleh Snell dkk (Snell et al., 2017). Model ini bekerja dengan mempelajari representasi *embedding* dan mengklasifikasikan data berdasarkan jarak antar fitur. Arsitektur *encoder* terdiri dari empat *convolutional block*, masing masing terdiri dari lapisan *Conv2D*, *Batch Normalization*, ReLU, dan *Max Pooling*. *Encoder* menghasilkan *embedding* berdimensi 128. *Prototype* untuk setiap kelas ditentukan sebagai rata-rata *embedding* seluruh sampel pada kelas tersebut. Proses klasifikasi dilakukan dengan menghitung jarak *Euclidean* antara data uji dengan setiap *prototype* kelas, kemudian kelas dengan jarak terkecil dipilih sebagai hasil prediksi. Model ini dilatih sepenuhnya dari awal tanpa *pretrained weights* menggunakan *optimizer* Adam dengan *learning rate*  $1 \times 10^{-4}$ . Fungsi *loss* yang digunakan adalah *Prototypical Distance Loss* berbasis *negative log likelihood*.



Gambar 4. Arsitektur *Prototypical Network from Scratch*

#### 2.5. Prosedur Pelatihan

Kedua model dilatih selama 50 *epoch* dengan *batch size* 32 (lihat Tabel 1 untuk rincian parameter pelatihan). Untuk menghindari *overfitting*, diterapkan *early stopping* dengan nilai *patience* sebesar 10 *epoch* berdasarkan nilai *training loss*. *Data augmentation* tidak digunakan pada penelitian ini agar perbandingan performa antara kedua model tetap adil dan murni berdasarkan kemampuan arsitektur. Proses pelatihan, evaluasi, dan pemilihan model digambarkan secara keseluruhan pada Gambar 5. Seluruh eksperimen dilakukan menggunakan *framework PyTorch* versi 2.0 dengan dukungan GPU, dan dijalankan dengan *random seed* yang sama untuk menjaga konsistensi serta reproduisibilitas hasil.



Gambar 5. Alur Penelitian

Tabel 1. Rincian Parameter Pelatihan

Parameter	<i>EfficientNet-B0</i>	<i>Prototypical Network</i>
Jumlah <i>epoch</i>	50	50
<i>Batch size</i>	32	32
Ukuran citra input	224 × 224	224 × 224
Optimizer	Adam	Adam
<i>Learning rate</i>	1×10 <sup>-4</sup>	1×10 <sup>-4</sup>
Fungsi <i>loss</i>	<i>Categorical Cross Entropy</i>	<i>Prototypical Distance Loss</i>
<i>Pretrained weight</i>	<i>ImageNet</i>	Tidak digunakan
<i>Early stopping</i>	<i>Patience 10 epoch</i>	<i>Patience 10 epoch</i>
Framework	<i>PyTorch 2.0</i>	<i>PyTorch 2.0</i>
<i>Environment</i>	GPU	GPU

## 2.6. Metode Evaluasi

Kinerja model dievaluasi menggunakan beberapa metrik, yaitu:

1. *Accuracy* untuk mengukur performa keseluruhan model,
2. *Macro Precision*, *Recall*, dan *F1-score* untuk menilai performa tiap kelas secara seimbang,
3. *Quadratic Weighted Kappa* (QWK) untuk mengukur tingkat kesesuaian prediksi dengan mempertimbangkan sifat ordinal tingkat keparahan DR,
4. *Confusion Matrix* untuk menganalisis performa pada setiap kelas,

Penggunaan QWK dipilih karena mampu memberikan penalti yang lebih besar pada kesalahan klasifikasi antar kelas yang berjauhan, seperti antara kelas *No DR* dan *Proliferative DR*, dibandingkan kesalahan pada kelas yang berdekatan.

## 2.7. Pengujian Statistik

Untuk mengetahui signifikansi perbedaan performa antara kedua model, dilakukan uji *Independent Samples t test* terhadap hasil prediksi model, dengan nilai 1 untuk prediksi benar dan 0 untuk prediksi salah. Besarnya pengaruh perbedaan kinerja dihitung menggunakan *Cohen's d* sebagai ukuran *effect*

size. Tingkat signifikansi yang digunakan adalah  $\alpha = 0,05$ . Seluruh proses analisis statistik dilakukan menggunakan *library SciPy* pada bahasa pemrograman *Python* (Cohen, 1988).

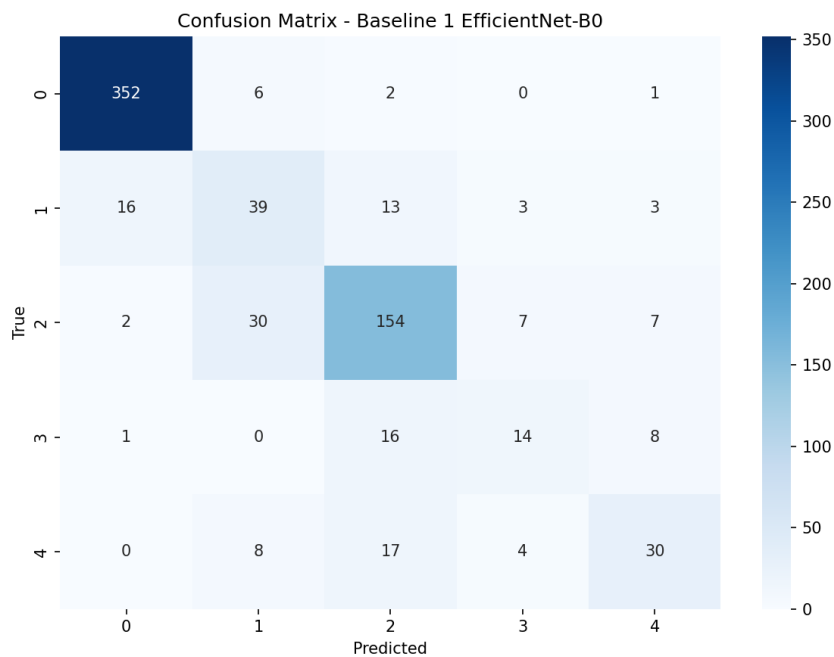
### 3. Hasil dan Pembahasan

Pada bagian ini disajikan hasil pengujian model *EfficientNet-B0 pretrained* dan *Prototypical Network from scratch* dalam klasifikasi *Diabetic Retinopathy*. Hasil penelitian ditampilkan dalam bentuk tabel dan analisis metrik evaluasi, kemudian dibahas secara komprehensif untuk mengetahui perbedaan performa kedua pendekatan yang digunakan.

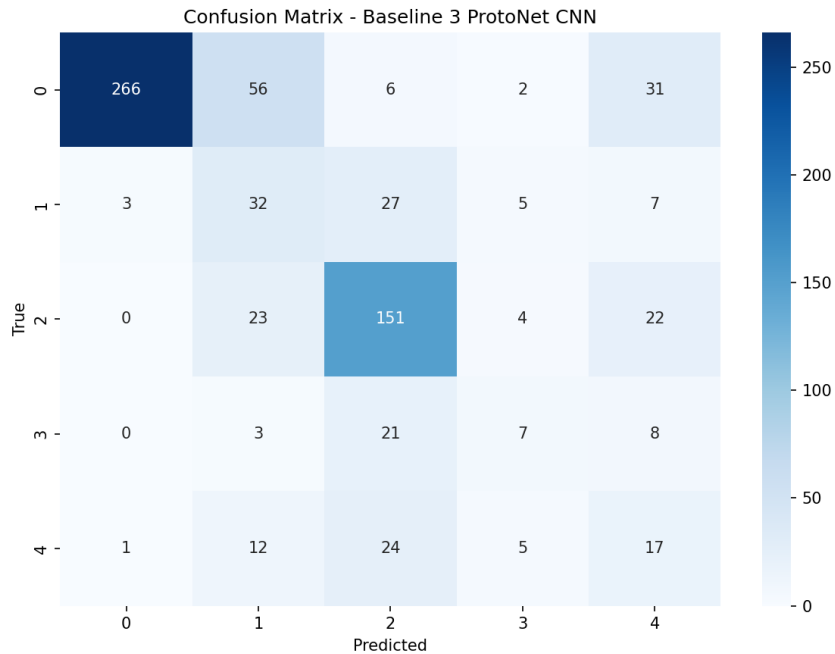
#### 3.1. Hasil Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *Quadratic Weighted Kappa* pada data uji sebanyak 733 citra fundus retina. Berdasarkan hasil pengujian, model *EfficientNet-B0 pretrained* memperoleh nilai *accuracy* sebesar 80,35 persen, *precision* 0,6587, *recall* 0,6279, *F1-score* 0,6396, dan nilai QWK sebesar 0,8529. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan tingkat keparahan *Diabetic Retinopathy* dengan tingkat kesesuaian yang tinggi. Sementara itu, *Prototypical Network from scratch* menghasilkan *accuracy* sebesar 64,53 persen, *precision* 0,4806, *recall* 0,4784, *F1-score* 0,4658, serta nilai QWK sebesar 0,5712, menunjukkan bahwa performa model masih relatif rendah terutama pada kelas dengan jumlah data yang sedikit.

Perbandingan hasil evaluasi kedua model dapat dilihat pada Tabel 1, sedangkan visualisasi performa klasifikasi per kelas ditunjukkan melalui *confusion matrix* pada Gambar 6 untuk *EfficientNet-B0 pretrained* dan Gambar 7 untuk *Prototypical Network from scratch*. *Confusion matrix* ini membantu untuk menganalisis kesalahan klasifikasi pada tiap kelas, misalnya kelas minoritas yang sering salah diklasifikasikan.



Gambar 6. Confusion Matrix *EfficientNet-B0 Pretrained*



Gambar 7. Confusion Matrix Prototypical Network from scratch

Tabel 2. Perbandingan Model

Model	Accuracy	Precision	Recall	F1-Score	QWK
<i>EfficientNet-B0 pretrained</i>	80,35	0,6587	0,6279	0,6396	0,8529
<i>Prototypical Network from scratch</i>	64,53	0,4806	0,4784	0,4658	0,5712

### 3.2. Analisis dan Pembahasan Hasil

Hasil penelitian menunjukkan bahwa *EfficientNet-B0 pretrained* memiliki performa yang lebih baik dibandingkan *Prototypical Network from scratch* pada seluruh metrik evaluasi. Selisih *accuracy* sebesar 15,82 persen dan perbedaan nilai QWK sebesar 0,2817 mengindikasikan adanya peningkatan performa yang signifikan. Keunggulan *EfficientNet-B0* dipengaruhi oleh penggunaan bobot *pretrained* yang telah mempelajari representasi fitur tingkat rendah hingga menengah dari *dataset* berskala besar, sehingga model mampu beradaptasi lebih cepat terhadap pola citra fundus retina meskipun jumlah data pelatihan terbatas. Sebaliknya, *Prototypical Network* yang dilatih dari awal sangat bergantung pada kualitas dan jumlah data latih. Pada kondisi *dataset* yang tidak seimbang, model mengalami kesulitan dalam membentuk *prototype* yang representatif, terutama pada kelas *Severe* dan *Proliferative Diabetic Retinopathy*, yang menyebabkan terjadinya kesalahan klasifikasi antar kelas dengan tingkat keparahan yang berdekatan. Nilai *Quadratic Weighted Kappa* yang lebih rendah pada model ini menunjukkan kecenderungan kesalahan prediksi pada kelas dengan jarak ordinal yang cukup jauh, kondisi yang kurang ideal dalam konteks medis karena berpotensi memengaruhi pengambilan keputusan klinis. Berdasarkan hasil tersebut, dapat disimpulkan bahwa pendekatan *transfer learning* lebih efektif dibandingkan pelatihan dari awal pada klasifikasi *Diabetic Retinopathy* dengan jumlah data terbatas dan distribusi kelas yang tidak seimbang.

#### 4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model *EfficientNet-B0 pretrained* memiliki kinerja yang lebih baik dibandingkan *Prototypical Network from scratch* dalam klasifikasi *Diabetic Retinopathy* menggunakan *dataset* APTOS 2019. Model *EfficientNet-B0* mampu menghasilkan nilai *accuracy* dan *Quadratic Weighted Kappa* yang lebih tinggi, yang menunjukkan kemampuan generalisasi dan tingkat kesesuaian prediksi yang lebih baik terhadap tingkat keparahan penyakit.

Perbedaan performa tersebut dipengaruhi oleh pemanfaatan bobot *pretrained* pada *EfficientNet-B0* yang memungkinkan model mempelajari representasi fitur secara lebih efektif meskipun jumlah data pelatihan terbatas dan distribusi kelas tidak seimbang. Sebaliknya, *Prototypical Network* yang dilatih dari awal masih mengalami keterbatasan dalam membentuk representasi kelas yang optimal, terutama pada kelas dengan jumlah data minoritas.

Berdasarkan temuan tersebut, pendekatan *transfer learning* direkomendasikan sebagai solusi yang lebih efektif dalam pengembangan sistem *Computer Aided Diagnosis* untuk klasifikasi *Diabetic Retinopathy*. Penelitian selanjutnya dapat mengembangkan metode ini dengan menambahkan teknik *data augmentation*, penanganan *data imbalance*, serta eksplorasi arsitektur *pretrained* lain guna meningkatkan performa model secara lebih optimal.

#### 5. Ucapan terimakasih

Penulis mengucapkan terima kasih kepada Program Studi Informatika Fakultas Ilmu Komputer Universitas Pembangunan Nasional Veteran Jawa Timur atas dukungan fasilitas dan lingkungan akademik yang menunjang pelaksanaan penelitian ini. Penulis juga menyampaikan apresiasi kepada *Asia Pacific Tele Ophthalmology Society* atas penyediaan *dataset* APTOS 2019 yang digunakan sebagai sumber data penelitian.

#### Daftar Pustaka

- Ahmed, F. (2025). *Addressing High Class Imbalance in Multi-Class Diabetic Retinopathy Severity Grading with Augmentation and Transfer Learning*. <http://arxiv.org/abs/2507.17121>
- 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), 30554. <https://doi.org/10.1038/s41598-024-81132-4>
- Chong, D. D., Das, N., & Singh, R. P. (2024). Diabetic retinopathy: Screening, prevention, and treatment. *Cleveland Clinic Journal of Medicine*, *91*(8), 503–510. <https://doi.org/10.3949/ccjm.91a.24028>
- Gu, C., & Lee, M. (2024). Deep Transfer Learning Using Real-World Image Features for Medical Image Classification, with a Case Study on Pneumonia X-ray Images. *Bioengineering*, *11*(4), 406. <https://doi.org/10.3390/bioengineering11040406>
- Hellín, C. J., Olmedo, A. A., Valledor, A., Gómez, J., López-Benítez, M., & Tayebi, A. (2024). Unraveling the Impact of Class Imbalance on Deep-Learning Models for Medical Image Classification. *Applied Sciences*, *14*(8), 3419. <https://doi.org/10.3390/app14083419>
- Kadhim, Y. A., Khan, M. U., & Mishra, A. (2022). Deep Learning-Based Computer-Aided Diagnosis (CAD): Applications for Medical Image *Datasets*. *Sensors*, *22*(22), 8999. <https://doi.org/10.3390/s22228999>
- Kropp, M., Golubnitschaja, O., Mazurakova, A., Koklesova, L., Sargheini, N., Vo, T.-T. K. S., de Clerck, E., Polivka, J., Potuznik, P., Polivka, J., Stetkarova, I., Kubatka, P., & Thumann, G. (2023). Diabetic retinopathy as the leading cause of blindness and early predictor of cascading complications—risks and mitigation. *EPMA Journal*, *14*(1), 21–42. <https://doi.org/10.1007/s13167-023-00314-8>
- Liu, Y., Shi, D., & Lin, H. (2024). Few-shot learning with representative global prototype. *Neural Networks*, *180*, 106600. <https://doi.org/10.1016/j.neunet.2024.106600>

- Ouahab, A., & Ahmed, O. Ben. (2025). ProtoMed: Prototypical networks with auxiliary regularization for few-shot medical image classification. *Image and Vision Computing*, 154, 105337. <https://doi.org/10.1016/j.imavis.2024.105337>
- Pachetti, E., & Colantonio, S. (2024). A systematic review of few-shot learning in medical imaging. *Artificial Intelligence in Medicine*, 156, 102949. <https://doi.org/10.1016/j.artmed.2024.102949>
- Snell, J., Swersky, K., & Zemel, R. S. (2017). *Prototypical Networks for Few-shot Learning*. <http://arxiv.org/abs/1703.05175>
- Srinivasan, S., Suresh, S., Chendilnathan, C., Prakash V, J., Sivaprasad, S., Rajalakshmi, R., Anjana, R. M., Malik, R. A., Kulothungan, V., Raman, R., & Bhende, M. (2023). Inter-observer agreement in grading severity of diabetic retinopathy in wide-field fundus photographs. *Eye*, 37(6), 1231–1235. <https://doi.org/10.1038/s41433-022-02107-1>
- Tan, M., & Le, Q. V. (2020). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*. <http://arxiv.org/abs/1905.11946>
- Teo, Z. L., Tham, Y.-C., Yu, M., Chee, M. L., Rim, T. H., Cheung, N., Bikbov, M. M., Wang, Y. X., Tang, Y., Lu, Y., Wong, I. Y., Ting, D. S. W., Tan, G. S. W., Jonas, J. B., Sabanayagam, C., Wong, T. Y., & Cheng, C.-Y. (2021). Global Prevalence of Diabetic Retinopathy and Projection of Burden through 2045. *Ophthalmology*, 128(11), 1580–1591. <https://doi.org/10.1016/j.ophtha.2021.04.027>
- Widyaya, J. E., & Budi, S. (2021). Pengaruh Preprocessing Terhadap Klasifikasi Diabetic Retinopathy dengan Pendekatan Transfer Learning Convolutional Neural Network. *Jurnal Teknik Informatika Dan Sistem Informasi*, 7(1). <https://doi.org/10.28932/jutisi.v7i1.3327>
- Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., Van Ginneken, B., Madabhushi, A., Prince, J. L., Rueckert, D., & Summers, R. M. (2021). A Review of Deep Learning in Medical Imaging: Imaging Traits, Technology Trends, Case Studies With Progress Highlights, and Future Promises. *Proceedings of the IEEE*, 109(5), 820–838. <https://doi.org/10.1109/JPROC.2021.3054390>
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences*. Lawrence Erlbaum Associates.
- Karthik; Maggie; Dane, S. (2019). *APTOS 2019 Blindness Detection*. Kaggle. <https://www.kaggle.com/competitions/aptos2019-blindness-detection>