

Fine-Grained Classificationによる糖尿病性網膜症の画像診断モデルの提案

谷口 善信^{1,a)} Muhammad Naseer Bajwa^{2,3,b)} 岩村 雅一^{1,c)} Andreas Dengel^{2,3,d)}
黄瀬 浩一^{1,e)} Sheraz Ahmed^{2,f)}

概要：近年、糖尿病性網膜症患者が増加しており、失明の原因となりうるため、糖尿病性網膜症の早期発見が重要視されている。Deep Neural Networkによる画像分類技術の発展に伴い、Deep Neural Networkを用いた画像診断が検討されているが、診断に用いる眼底画像における糖尿病性網膜症の兆候は微細かつ散在しているため、診断が困難である。本研究では、Deep Neural Networkを用いた糖尿病性網膜症の画像診断を目標に、Fine-Grained Classificationの手法を組み合わせたモデルを提案する。

1. はじめに

近年、糖尿病が生活習慣病として問題視されており、糖尿病性網膜症 (Diabetic Retinopathy, DR) の患者が増えている。DR は自覚症状が少なく、症状が進行すれば失明の原因となるため、早期発見が重要である。現在、医師の負担軽減と医師の少ない地域での DR の早期発見のために、コンピュータによる画像診断が検討されている。

Deep Neural Network (DNN) の発展に伴い、医療分野での DNN の活用が注目されている。DNN による DR の画像診断の課題は、DR の小さく散在している兆候の検出と画像の質のばらつきである。同様の課題を抱えたものに、犬、猫など一般的な分類ではなく、犬種などのより詳細な分類を目的とした Fine-Grained Classification (FGC) がある。FGC では画像内の重要な部分に注目することでこの問題に対応しており、様々な手法が提案されている。

そこで本研究では、DR の認識精度の向上のため、FGC の手法を組み合わせた画像診断モデルを提案する。

2. 関連研究

Lam ら [2] は前処理に Contrast Limited Adaptive His-

togram Equalization (CLAHE) を適応し、CLAHE と質の良いデータが DR の認識精度を向上させると示した。

3. 提案手法

本研究では FGC の手法である NTS-Net [7] と Saliency-Sampler [6]、一般画像分類に用いられる ResNet-50 [4]、DenseNet-201 [5]、NasNet [8] を組み合わせ、アンサンブル学習を行った。

4. 実験

EyePACS dataset [1] と Messidor-1 を用いて提案手法の学習と評価を行った。Lam らは Messidor-1 [3] を用いて眼底画像から DR の進行度を 4 段階で推論する 4 クラス分類を行い、57.2% の認識率を達成した。同様に 3 クラス分類では 68.8%，重度の DR を検出する 2 クラス分類では 74.5% の認識率を達成した。それに対して提案手法は 4 クラス分類において EyePACS dataset で 83.42%，Messidor-1 で 76.25%，3 クラス分類では 84.94% と 85.25%，重度の DR を検出する 2 クラス分類では 95.89% と 93.25%，加えて健常者と罹患者を分類する 2 クラス分類では 88.19% と 89.75% の認識率を達成し、精度の向上が見られた。

5. まとめ

本研究では、FGC の手法を組み合わせた DR の画像診断モデルを提案した。実験結果より、NTS-Net は DR の識別に有効な手法であり、精度を向上させることが可能だと示された。また、初期段階における DR の特徴は非常に微細であり、特に認識が困難であると示された。

¹ 大阪府立大学大学院工学研究科

² German Research Center for Artificial Intelligence GmbH (DFKI)

³ Technische Universitaet Kaiserslautern

a) taniguchi@m.cs.osakafu-u.ac.jp

b) bajwa@dfki.de

c) masa@cs.osakafu-u.ac.jp

d) andreas.dengel@dfki.de

e) kise@cs.osakafu-u.ac.jp

f) sheraz.ahmed@dfki.de

参考文献

- [1] Diabetic Retinopathy Detection, <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>.
- [2] Carson Lam, D. Y., Guo, M. and Lindsey, T.: Automated detection of diabetic retinopathy using deep learning, *AMIA Summits on Translational Science Proceedings*, Vol. 2017, p. 147 (2018).
- [3] Decencire, E., Zhang, X., Cazuguel, G., Lay, B., Cochener, B., Trone, C., Gain, P., Ordonez, R., Massin, P., Erginay, A., Charton, B. and Klein, J.-C.: Feedback on a publicly distributed database: the Messidor database, *Image Analysis & Stereology*, Vol. 33, No. 3, pp. 231–234 (online), DOI: 10.5566/ias.1155 (2014).
- [4] He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778 (2016).
- [5] Huang, G., Liu, Z., van der Maaten, L. and Weinberger, K. Q.: Densely Connected Convolutional Networks, *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2261–2269 (2017).
- [6] Recasens, A., Kellnhofer, P., Stent, S., Matusik, W. and Torralba, A.: Learning to Zoom: A Saliency-Based Sampling Layer for Neural Networks, *Proc. 2018 European Conference on Computer Vision (ECCV)* (2018).
- [7] Yang, Z., Luo, T., Hu, Z., Gao, J. and Wang, L.: Learning to Navigate for Fine-Grained Classification, *Proc. 2018 European Conference on Computer Vision (ECCV)* (2018).
- [8] Zoph, B. and Le, Q. V.: Neural Architecture Search with Reinforcement Learning, *Proc. 2017 International Conference on Learning Representations (ICLR)*, (online), available from <<https://arxiv.org/abs/1611.01578>> (2017).