

加齢黄斑変性の眼底写真からの 滲出性病変有無判定における GoogLeNet 転移学習の試み

Applying GoogLeNet for classifying exudative lesions with AMD based on fundus images

杉山 治^{1*} 細田 祥勝² 三宅 正裕² 大槻 涼³
平木 秀輔¹ 山本 豪志朗¹ 田村 寛⁴ 辻川 明孝² 黒田 知宏¹
Osamu Sugiyama¹ Yoshikatsu Hosoda² Masahiro Miyake² Ryo Otsuki³
Shusuke Hiragi¹ Goshiro Yamamoto¹ Hiroshi Tamura⁴
Akitaka Tsujikawa² Tomohiro Kuroda¹

¹ 京都大学医学部附属病院

¹ Kyoto University Hospital

² 京都大学大学院医学研究科

² Graduate School of Medicine, Kyoto University

³ 立命館大学

³ Ritsumeikan University

⁴ 京都大学国際高等教育院

⁴ Institute for Liberal Arts and Sciences, Kyoto University

Abstract:

Age-related macular degeneration (AMD) is a major cause of blindness in developed countries. Generally, treatment indication for AMD is judged by the presence of exudative lesion checked at each visit. The presence of an exudative lesion is judged by optical coherence tomography (OCT), but the number of facilities equipped with OCT is limited. Classifying the presence of exudative lesion from the fundus photography would be essential for improving diagnostic accuracy in facilities without OCT.

In this study, we aim to classify the presence of exudative lesions in AMD by using machine learning with fundus photographs. Precedent studies revealed that it was effective to apply deep learning with fundus photographs to improve the classification performance drastically. With regard to belonging researches, we use the classifier pre-trained with a data set for general image processing called GoogLeNet and finetuned the AMD classifier with a transfer learning. In this study, it was verified the trained classifier with a GoogLeNet transfer learning was effective for judging the presence of exudative lesion from fundus photographs, which is difficult even for a human doctor.

1 はじめに

加齢黄斑変性 (Age-related Macular Degeneration, AMD) は先進国の失明原因として上位を占める疾患である。当該疾患では一般に、受診ごとに滲出性病変の有無を判定し、治療適応を判定する。滲出性病変の有無の判定は光干渉断層計 (optical coherence tomography,

OCT) によるのが確実であるが、導入施設は限られている。眼底写真から滲出性病変の有無判定を補助できれば、OCT を持たない施設における診断精度の向上が期待できる。

本研究では、加齢黄斑変性における滲出性病変有無判定を機械学習によって学習された識別器を用いて行うことを目標とする。眼底写真から画像識別手法を用いて、病変を識別する研究は、深層学習を用いた識別学習の試みとしてすでに行われており、有効な結果を出すことが明らかとなった [2]。該当研究においては、

*連絡先：京都大学医学部附属病院
先制医療生活習慣病研究センター
〒606-8507 京都府京都市左京区聖護院川原町5-4
E-mail: sugiyama@kuhp.kyoto-u.ac.jp

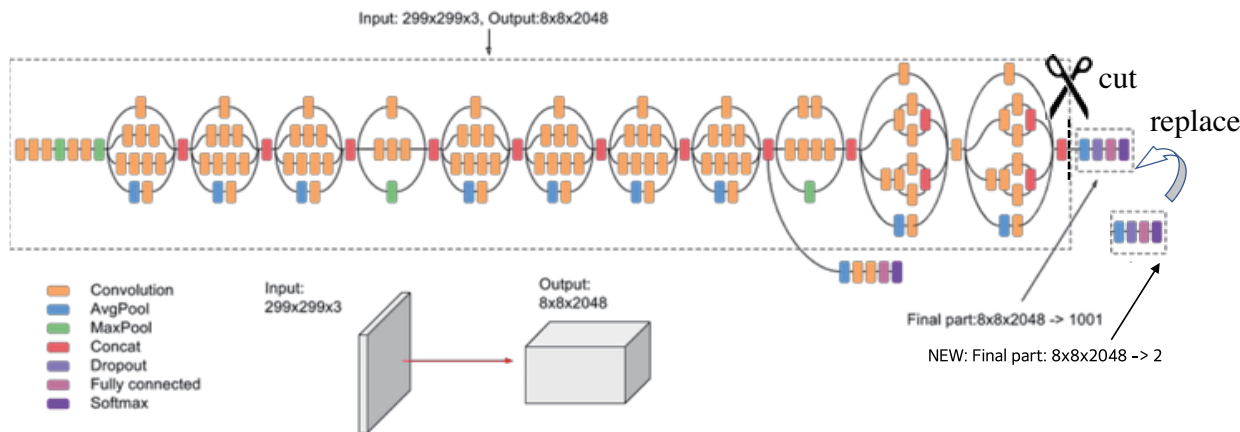


図 1: GoogLeNet による転移学習¹

Google 社が公開している GoogLeNet[1] と呼ばれる一般画像認識のためのデータセットで学習された学習済み識別器を用い、これを転移学習 [3] することで顕著な結果を出している。本研究では、既存研究に基づいた上で、人間の医師でも眼底写真からの判定が難しい滲出性病変有無判定でも、学習済み識別器による転移学習が有効であるのかを検証した。

GoogLeNet からの転移学習で考慮すべき点として、ImageNet という一般画像認識のデータセットを用いて学習されているという点が挙げられる。具体的には 1,000 クラスの分類器として学習された GoogLeNet の識別モデルを、滲出性病変有無判定の 2 クラス分類をする識別器に適用する必要がある。そこで、本研究では識別部の構造を一部変更した上で部分的に転移学習を行った。

実験においては、同じく ImageNet の学習に用いられた VGG16 という基本的な畳み込みニューラルネットワークの構造をもつモデルと比較することにより、ネットワーク構造の違い、転移学習の有無によって学習の推移と、識別精度にどのような差が表れるのかを明らかにした。

2 提案方法

本研究では、ImageNet で学習済みの GoogLeNet 識別器を転移学習することにより、滲出性病変有無判定を行う高精度な識別器を得ることを目的とする。図 1 に転移学習における操作を示す。

図 1 では、Google が公開している学習済み識別器の中でも Inception v3 の識別モデルを例にとって、1,000

クラスの識別を行う識別器を滲出性病変有無 (Dry or Wet) の判定を行う 2 クラスの識別器に変換する操作を述べる。1,000 クラス分類を 2 クラス分類に変更する上で、変更すべき部位は、最終段のフィードフォワード層である。図 1 に示す通り、まず、学習済み Inception V3 の識別器のフィードフォワード層を切り取る。次に、2 クラス分類のためのフィードフォワード層を切り取った部分に入れることで、1,000 クラス分類から 2 クラス分類の識別器への変換を行う。この際、切り取ったフィードフォワード層の学習済みのパラメータは失われ、新たに 2 クラス分類の初期化されたパラメータが割り当てられる。転移学習においては、フィードフォワード層以外の学習済みパラメータと、2 クラス分類のフィードフォワード層のパラメータを用いて、部分転移学習を行った。

3 実験

本実験では、GoogLeNet 識別器を転移学習することにより、滲出性病変有無判定を行う識別器の精度が向上することを確かめる。比較対象として、本実験では同じく ImageNet の学習に用いられた VGG16 をベースラインとして、その精度の比較を行った。VGG16 は 2014 年の ILSVRC (ImageNet Large Scale Visual Recognition Challenge) で提案された畳み込み層 13 層とフル結合層 3 層の計 16 層から成る畳み込みニューラルネットワークである。一般的な CNN の構成とほとんど変わらないため、本実験では比較対象として用いた。実験では、転移学習なし・ありの 2 条件でこれら識別器の識別制度を比較した。

¹Inception V3 のイメージは以下の URL の画像を使用しました。
<https://cloud.google.com/tpu/docs/inception-v3-advanced>




図 2: VGG16




図 3: VGG16 転移学習




図 4: Inception V3




図 5: Inception V3 転移学習

3.1 実験手順

実験には、京都大学医学部附属病院の眼科で集められた AMD の眼底写真 1824 枚を用いた。これらの眼底写真は、光干渉断層計により診断された浸出性病変の有無がラベルづけされており、それぞれの内訳は、滲出性病変有 898 枚、滲出性病変無 926 枚となる。また、患者数では 454 名の眼底写真（左右、複数回）の画像を用いた。学習においては、全体の 80.0% を識別学習に、20.0% を評価に用いた。また、実験に用いた画像のサイズは、 2448×3696 ピクセルであり、RGB の 3 チャンルの画像であったが、学習に用いるには大きすぎるため、 $480 \times 480 \times 3$ の画像行列に変換して、学習に用いた。

学習条件については、それぞれの条件において、学習回数は 100 epoch とし、バッチサイズは 20 とした。学習に用いた計算機は、Intel(R) Xeon(R) CPU E5-1620 v4 @ 3.50GHz の CPU、94 Gb のメモリ、TITAN X (Pascal) の GPU を積んだ。ソフトウェアとしては、

keras 2.2.0²、tensorflow 1.8.0³をそれぞれ用いた。

3.2 実験結果

図 2 から図 5 までにそれぞれの条件での学習結果の推移を表す。図はそれぞれ条件における学習曲線であり、左側の縦軸が精度 (accuracy) を、右側の縦軸が loss の値を、そして、横軸が学習回数 (epoch) を示す。また、図中、赤線が loss を青線が精度の推移を表す。

図 2, 3 を見ると、VGG16 においては転移学習はうまく作用せず、むしろ局地に陥って学習が進んでいないことが見て取れる。また、転移学習をしない条件においても、識別精度の向上が見られなかった。

一方、図 4, 5 を見ると InceptionV3 においては転移学習が成功し、Inception V3 を転移学習したモデルが 4 つの条件の中でもっとも学習に成功していることが見て取れる。転移学習なしの Inception V3 においては学

²<https://github.com/keras-team/keras/releases/tag/2.2.0>

³<https://github.com/tensorflow/tensorflow/releases>

表 1: 実験結果

指標	転移学習	VGG16	Inception V3
精度	無	0.50	0.57
	有	0.50	<u>0.79</u>
適合率	無	0.00	0.56
	有	0.50	<u>0.79</u>
再現率	無	0.00	0.36
	有	<u>1.00</u>	0.67
F 値	無	0.00	0.43
	有	0.67	<u>0.73</u>

習そのものは進んでいるものの、精度の向上は転移学習をしたものと比較して、低い精度での推移に止まった。

次に、学習回数 100 において、それぞれの条件における精度・適合率・再現率・F 値のそれぞれの最高値を表 1 に示す。各指標について、最も数値が高い数値については下線を引いて示した。全条件中、もっとも精度が高かったのは転移学習ありの Inception V3 であり、他の条件と比較して、0.20 以上の精度の向上が見られた。適合率、再現率、F 値においても同じ傾向が見られるが、VGG16 の条件において、転移学習なしのときの適合率が 0.50、再現率が 1.00 なのに対し、転移学習ありのときの適合率・再現率がともに 0.0 であるのは全てを陽性と回答する、もしくは陰性と回答する識別器が学習されたためである。この結果からも学習がうまく進んでいないことが見て取れる。

4 考察

本研究では、GoogLeNet による転移学習によって、高精度の AMD 滲出性病変有無判定の識別器を学習できるかを検証した。実験を通じて、ImageNet によって学習済みの Inception V3 を転移学習させた識別器が、その他の条件のものより高い精度を得ることがわかった。

一般画像認識用のデータセットである ImageNet を用いて学習された画像分類器の重みが、なぜ眼底写真の識別においても有効であるのか、その理由は明らかではないが、人間の医師でも区別が難しい眼底写真からの AMD 滲出性病変有無判定を 0.80 に近い精度で判定可能であることがわかったため、今回の試みは有効であったと考える。また、VGG16 においては、同じ転移学習を用いても高い識別精度が得られなかったことから、Inception V3 がもつ複雑なネットワーク構造が精度向上に寄与しているものと考えられる。

既存研究における AMD の有無判定においても、1.0 に近い精度を出し、今回の AMD 滲出性病変有無判定でも 0.80 に近い精度を出したことから、GoogLeNet を転移学習することで識別精度の向上を試みることは他の眼底写真からの病変判定にも広く適用できるのではないかと考えられる。

また、今回の転移学習においては、フィードフォワード層を従来の 1,000 クラス識別をするものから、2 値分類をするものに置き換えて学習を行った。その際、ベースラインを設定して比較はしていないが、フィードフォワード層への結合層として、GlobalAveragePooling を用いたもの [5] と、単に横展開をする Flatten 層を用いたものでは学習効率が顕著に変化した。転移学習をする際、どのように目的のクラスの識別器に置き換えるのか、その構成方法にも工夫が必要であると考えられる。

将来課題として、他の GoogLeNet も含めてより広く検証を行うこと、また、転移学習をする際にどのように画像を入力として与え、出力層を設計するのが効率的なのかを検証することが挙げられる。

5 おわりに

本研究では、加齢黄斑変性における滲出性病変有無判定を機械学習によって学習された識別器を用いて行うことを目標とし、学習済み一般画像識別器である GoogLeNet をベースとして高精度の 2 クラス分類器の転移学習を行なった。実験の結果、Inception V3 を部分転移学習させることで、人間の医師にも難易度の高い、眼底写真からの滲出性病変有無判定を 0.79 の識別精度で識別することができるモデルを学習することができた。

参考文献

- [1] CANZIANI, Alfredo; PASZKE, Adam; CULURCIELLO, Eugenio. An analysis of deep neural network models for practical applications. arXiv preprint arXiv:1605.07678, 2016
- [2] Li, Zhixi, et al. "Efficacy of a Deep Learning System for Detecting Glaucomatous Optic Neuropathy Based on Color Fundus Photographs." *Ophthalmology* (2018).
- [3] Huh, Minyoung, Pulkit Agrawal, and Alexei A. Efros. "What makes ImageNet good for transfer learning?." arXiv preprint arXiv:1608.08614 (2016).
- [4] Kornblith, Simon, Jonathon Shlens, and Quoc V. Le. "Do Better ImageNet Models Transfer Better?." arXiv preprint arXiv:1805.08974 (2018).
- [5] LIN, Min; CHEN, Qiang; YAN, Shuicheng. Network in network. arXiv preprint arXiv:1312.4400, 2013.