




11/9 システム医科学特論


眼科 高橋知成

Prediction of causative genes in inherited retinal disorder from fundus photography and autofluorescence imaging using deep learning techniques

Yu Fujinami-Yokokawa  ^{1,2,3,4} Hideki Ninomiya,² Xiao Liu,¹ Lizhu Yang,¹
Nikolas Pontikos  ^{1,3,5} Kazutoshi Yoshitake,⁶ Takeshi Iwata,⁶ Yasunori Sato,^{4,7}
Takeshi Hashimoto,^{4,8} Kazushige Tsunoda,⁹ Hiroaki Miyata,^{2,4} Kaoru Fujinami  ^{1,3,5}
The Japan Eye Genetics Study (JEGC) Group

Hot topic

これまで
網膜剥離
(手術方法、術後成績向上など)



現在
gene therapy
(治療方法がこれまでなかったもの)

直接目に見える治療は成熟期を迎え、遺伝子疾患の
診断並びにその治療にフォーカス

ABCA4 Stargart病

RP1L1 網膜色素変性

EYS occult macular gystrophy


Normal

の4つを対象


眼底写真と眼底自発蛍光を用いて判断

AlgorithmはMedicMindを使用（TensorFlowV.3を用いたもの）

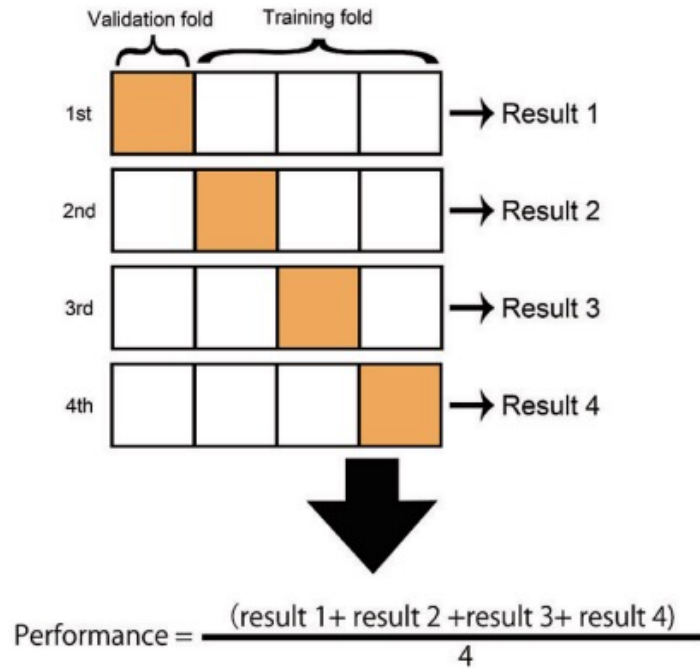
Stargart病



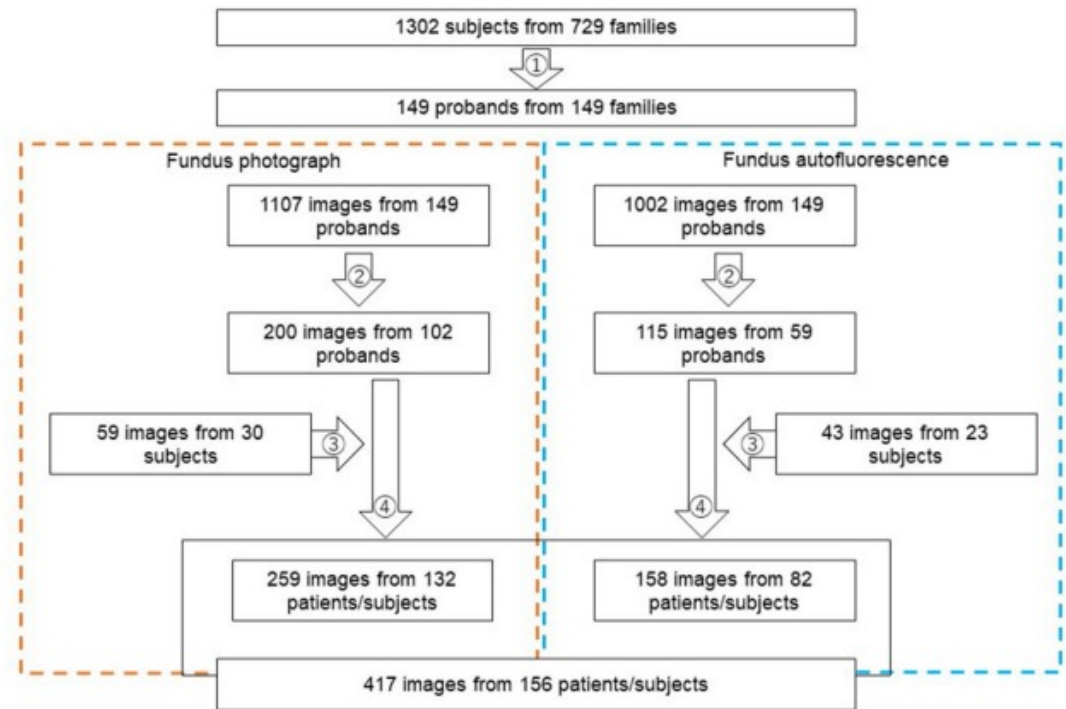
網膜色素変性症



Supplemental Figure 1. A randomised 4-fold cross-validation method

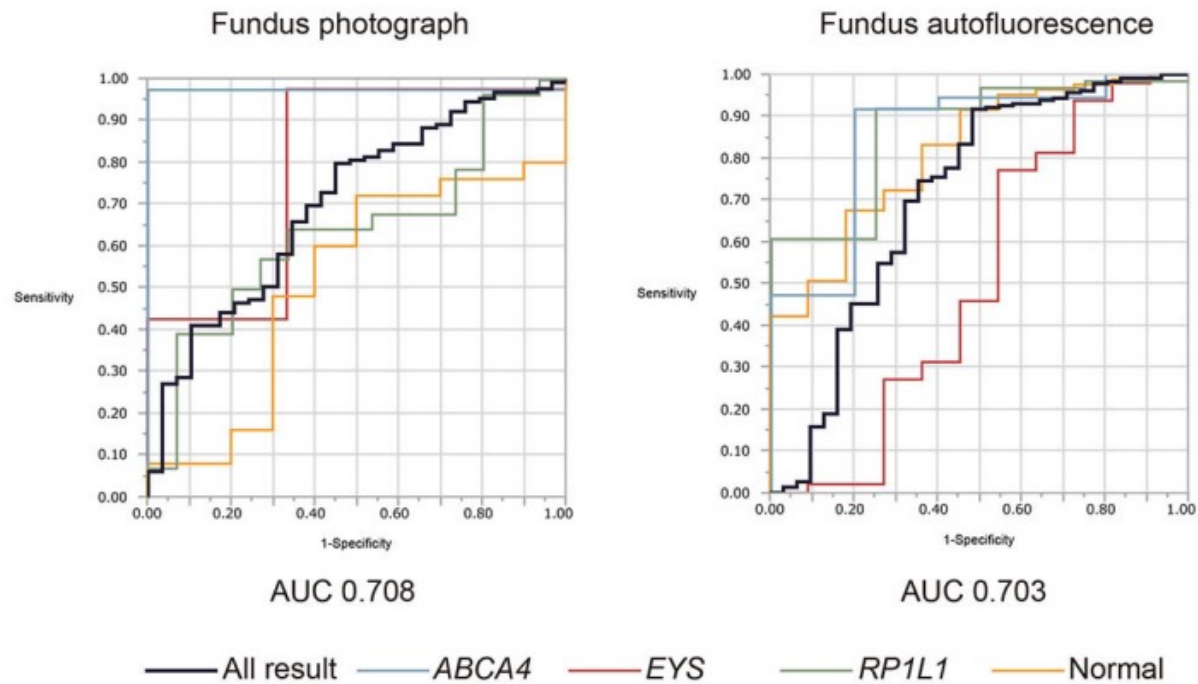


Supplemental Figure 2: The detailed filtration/selection flow of the examined images



The filtration/selection process include ① selecting three genes (*ABCA4*, *EYS*, *RP11L1*) based on the disease prevalence, ② selecting one image from one eye by an expert, ③ selecting normal images by an expert (excluding images with inadequate dataset/quality), and ④ fixing the dataset for machine learning.

Supplemental Figure 3. Performance of the artificial intelligence (AI) diagnosis model



The receiver operating characteristic (ROC) curves of fundus photography and fundus autofluorescence imaging were generated. The area under the curve (AUC) for each result was 0.708 (95% confidential interval (CI): 0.589-0.829) for fundus photography and 0.703 (95% CI: 0.600-0.808) for fundus autofluorescence imaging. ROC for the four categories was also illustrated: *ABCA4* retinopathy, *EYS* retinopathy, *RP1L1* retinopathy, and normal.

AN IMAGE IS WORTH 16X16 WORDS: TRANSFORMERS FOR IMAGE RECOGNITION AT SCALE

**Alexey Dosovitskiy^{*,†}, Lucas Beyer^{*}, Alexander Kolesnikov^{*}, Dirk Weissenborn^{*},
Xiaohua Zhai^{*}, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer,
Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, Neil Houlsby^{*,†}**

^{*}equal technical contribution, [†]equal advising
Google Research, Brain Team

Visual transformerについて

“Attention is all you need”
Transformerというモデル

これまで文章認識においてRNNやCNNが使われていた
長文の依存関係を掴めない
Attentionのみを使っている

Attentionとは
文中の単語の意味を理解する時に文中の単語のどれに注目すれば良い
かを表すスコアのこと（query, key, valueのパラメータ）

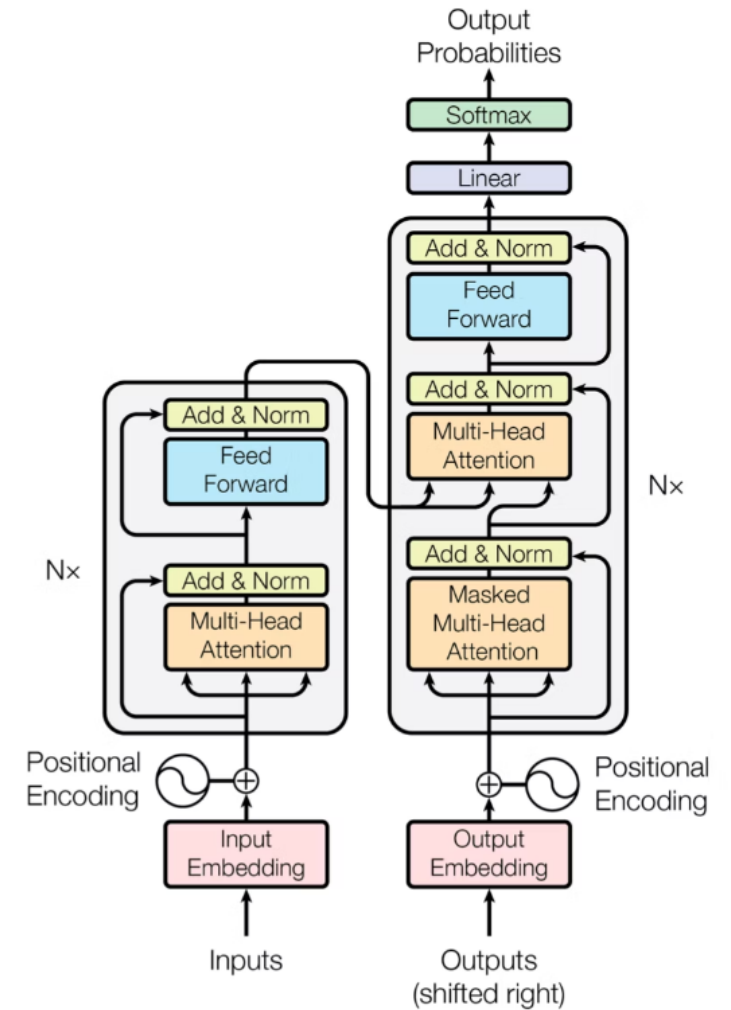
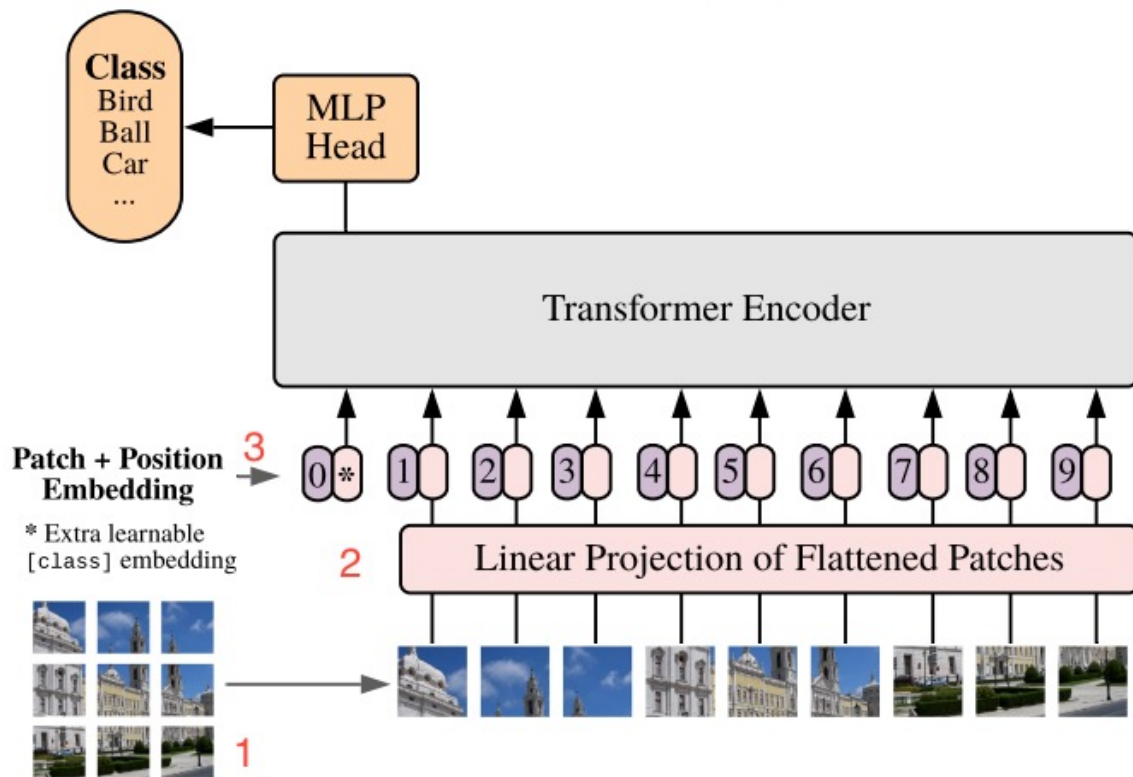


Figure 1: The Transformer - model architecture.

Transformerを画像認識に応用したのがVision Transformer(ViT)



画像パッチを単語のように扱う
(Transformerを応用)

SoTAを上回る性能を1/15の計算コストで達成

事前学習

ILSVRC-2012: クラス1000個の計130万枚

ImageNet: クラス21000個の計1400万枚

JFT-300M: クラス18000個の計3億枚

巨大なデータセットを用いた事前学習で真価を發揮した

Are we done with ImageNet?

Lucas Beyer^{1*} Olivier J. Hénaff^{2*} Alexander Kolesnikov^{1*} Xiaohua Zhai^{1*} Aäron van den Oord^{2*}

¹Google Brain (Zürich, CH) and ²DeepMind (London, UK)

2020年6月にGoogle Brainから出された論文
画像認識の性能評価に使われるImageNetに対して疑問視

ImageNetとは？

画像認識のベンチマークとして使用されるデータセット
1400万枚以上のイメージ画像にラベルが付与されている

SotA "State of the Art"という指標が機械学習において最先端にあるかどうかの判別として使われている

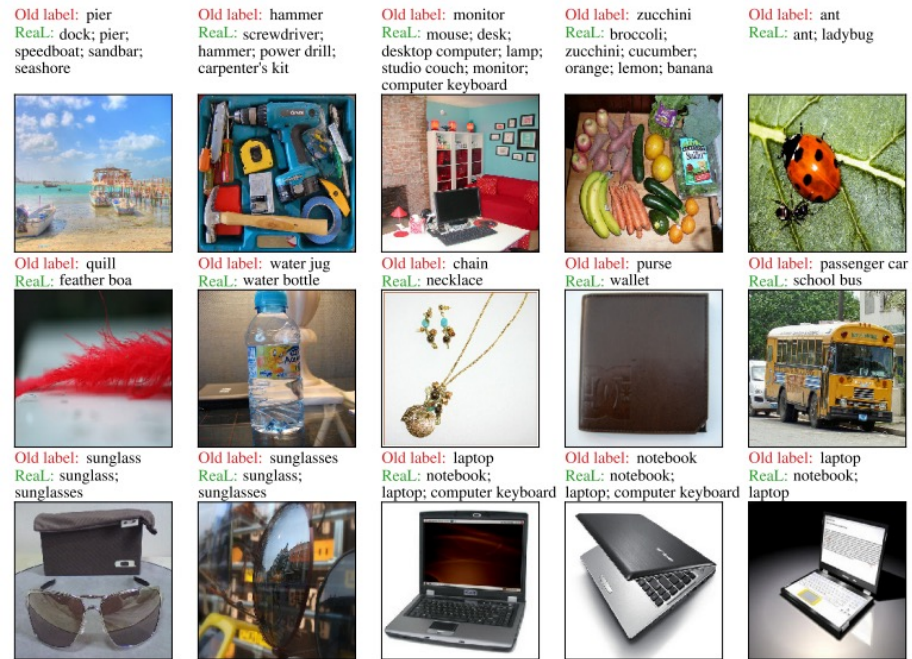



Figure 2: Example failures of the ImageNet labeling procedure. Red: original ImageNet label, green: proposed ReaL labels. **Top row**: ImageNet currently assigns a single label per image, yet these often contain several equally prominent objects. **Middle row**: Even when a single object is present, ImageNet labels present systematic inaccuracies due to their labeling procedure. **Bottom row**: ImageNet classes contain a few unresolvable distinctions.



ReaL(Reassessed Labels)という新たなラベル付けを行っている

Relabeling the ImageNet validation set

1. Collecting a comprehensive set of proposals (候補ラベルの生成)

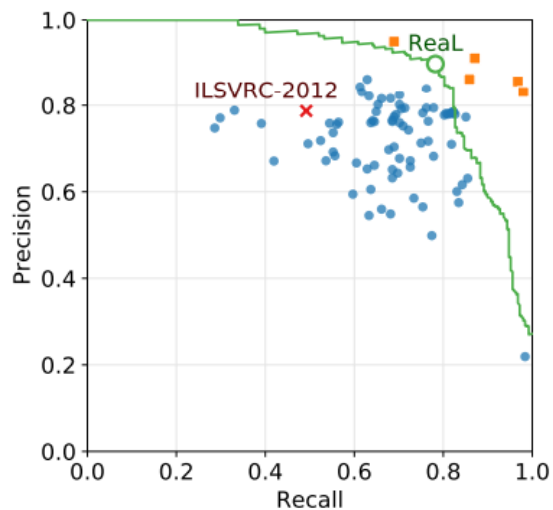
ImageNetのラベルと19個のモデルのラベルを全て用いる

5人の専門家によりラベル付けされた256枚の画像をゴールドスタンダードとして、19のモデルの中から最適な組み合わせを見つける

2. Human evaluation of proposed labels (人間による候補ラベルの評価)

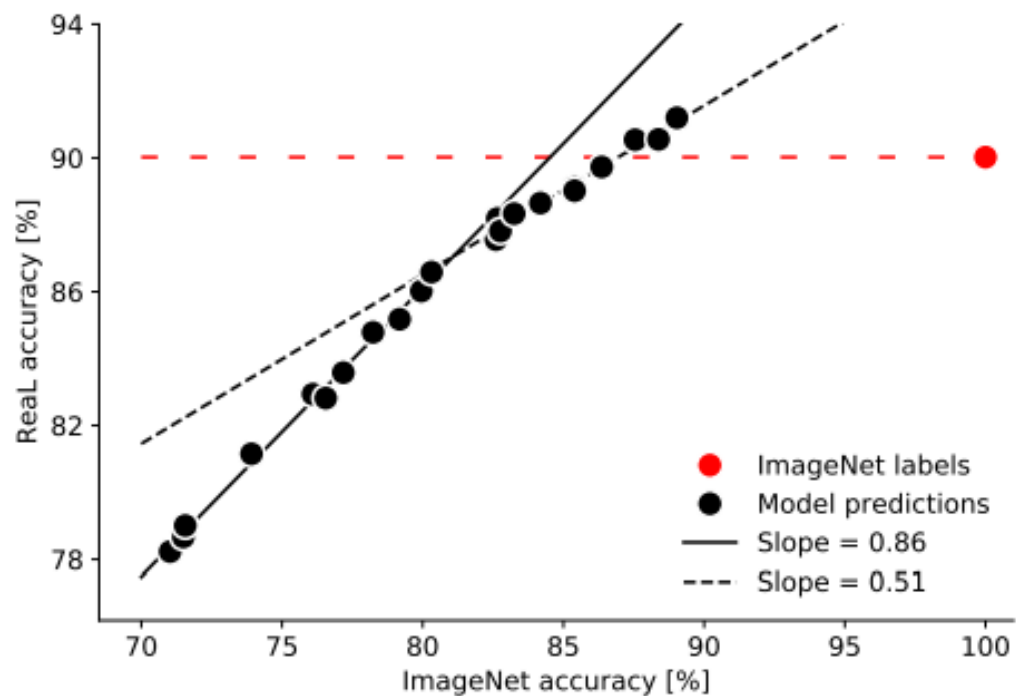
それぞれのラベリングに対して5人のアノテーターが行う

3. From human ratings to labels and a metric (アノテーターの評価に基づくラベルづけ)



結果：ReaLの方がより正確

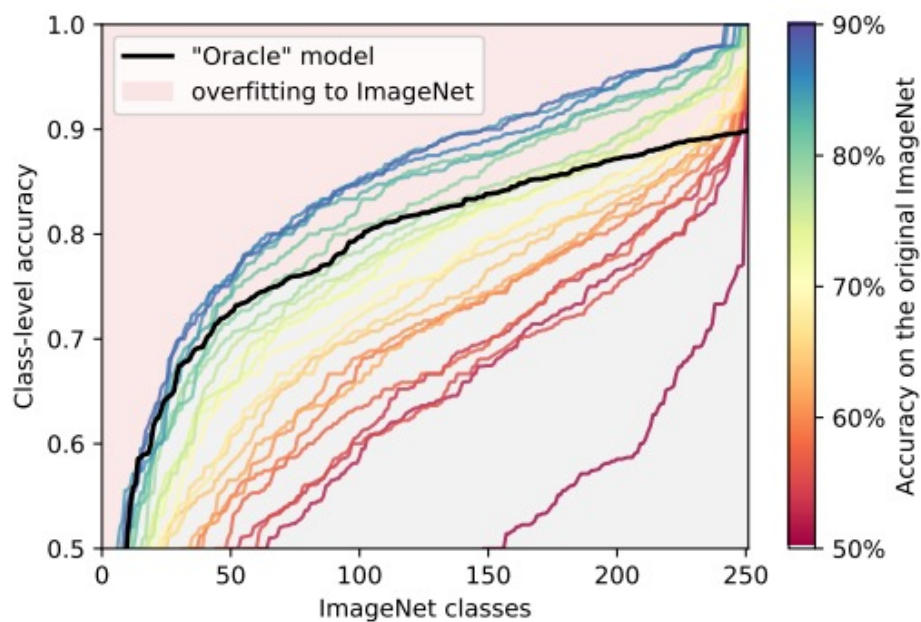
Re-evaluating the state of the art SoTAモデルの再評価



黒実線は初期モデル
黒点線は最新モデル

モデルによってはReaLを超える精度をだしている
(=Imagenetのオリジナルラベルよりも正確なラベルを予測している)
→間違っているラベルを過学習しているだけ

An analysis of co-occurring classes



Oracleモデル

ReaLにおいて複数の正解ラベルを持つ画像に対してそのうちの1つをランダムに選ぶモデル

OracleモデルをImageNetラベルを正解として評価する
Oracleよりも高い性能を示すとすればそれはImageNetにバイアスが存在することを示す



ImageNet学習モデルが複数ラベルを含む画像に対して正解となるラベルをランダムで1つ答えているのかバイアスが存在しているのかという疑問

本論文で伝えられていること

Are we done with ImageNet?

No→ ImageNetにはバイアスと過学習の問題があり、そのまま使用されることは今後少ない

Yes→ ReaLラベルを用いることで改善すれば今後も利用することができる