

Fewshot Learning の最新手法は本当に良いのか？

高橋 佑輔[†] 長崎 大^{††}
[†] 東北大学工学部電気情報物理工学科

宮崎 智^{††} 大町 真一郎^{††}
^{††} 東北大学大学院工学研究科通信工学専攻

1. はじめに

Fewshot Learning とは画像分類のタスクにおいて、限られた枚数の学習画像を用いて画像認識するタスクである。最新手法である MAML[1]は、既存の分類モデルに対する新しい学習方法を提案し、より Fewshot Learning のタスクに最適化された学習を可能としている。

本研究では、Fewshot Learning の最新アプローチである MAML と一般的な画像認識手法である VGG13[2]を比較することで、最新手法の有効性を明らかにする。

2. MAML++

MAML は、適応したいタスクと同じタスクを大量に作成し、それらの学習を通じて、タスクに共通して有用なパラメータを学習していく。それにより、学習データに限られる場合でも新しいタスクに素早く適応することができる。本研究では MAML の改良版である MAML++[3]を用いた。

MAML++の学習フローを図1に示す。

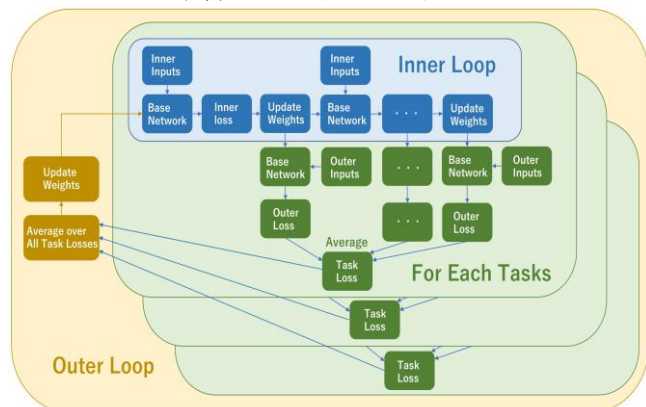


図1. MAML++における学習フロー

まず、Inner Loop でタスクを Base Network で学習していく。ここで Inner loop で Base Network のパラメータを更新するたびに、学習には用いていない同クラスのデータで Loss を計算し Task Loss として蓄積させていく。これを複数のタスクに関して行い、それぞれの Task Loss の平均を求める(Average over All Task Losses)。最後にその Loss をもとに Base Network のパラメータを更新する(Outer Loop)。これを繰り返すことで、タスクに関して汎用的なモデルの初期パラメータを学習する。

3. 実験の設定

本実験では 5-way 5-shot, 5-way 10-shot の分類タスクを考えた。n-way k-shot の分類タスクとは、学習データとして 1 クラスあたり k 枚の画像が与えられる、n クラス分類のタスクを指す。

学習データとして CIFAR100 の 90 クラス分のデータを使

用し、残りの 10 クラスをテストデータとして使用した。

MAML++において Base Network には VGG13 を使用した。また、Outer Loop を 150 回、各 Outer Loop において Task 数を 2 とし、各 Task において Inner Loop を 5 回繰り返した。

また、MAML++の比較対象として 2 つのモデルを用意した。1 つは、学習済み VGG13 を MAML++の学習に用いた 90 クラスから 5 クラスずつ選び finetuning をする作業を 150 回繰り返した後、最後にテストデータから選んだ 5 クラスで finetuning したモデル(VGG13(finetuning))である。もう 1 つは学習済み VGG13 をテストデータから選んだ 5 クラスのみで finetuning したモデル(VGG13(pretrained))である。

4. 実験結果

実験結果を表 1 に示す。MAML++ と VGG13(pretrained)の分類精度の差は 0.72%とわずかであった。これは、VGG13 のような軽量なネットワークにおいては、少ない枚数の画像で学習させてもすぐにパラメータが収束するため、MAML++により学習した初期パラメータの影響がごく小さかったためだと考えられる。また、VGG13(finetuning)は他のモデルと比較して著しく精度が悪かったため、テストデータと異なるクラスのデータでどれだけ finetuning をしても、テストデータに関する有用な学習ができない、すなわち、タスクに関して汎用的な学習はできないことがわかった。

表 1. CIFAR100 の 5-way Fewshot 分類精度[%]

	5-shot	10-shot
MAML++	40.36	49.34
VGG13 (finetuning)	25.52	26.08
VGG13 (pretrained)	39.42	48.62

5. まとめ

本稿では、Fewshot Learning における学習手法ごとの精度を比較した。その結果、MAML++は VGG13 を上回るものの、その差は 0.72%とわずかであった。これは VGG13 が比較的軽量なモデルであり、パラメータの収束が速いため、少数の画像でも MAML++と同じように学習できたためだと考えられる。

参考文献

- [1] C. Finn et al., “Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks,” ICML, 2017
- [2] K. Simonyan et al., “Very Deep Convolutional Networks few Large-Scale Image Recognition,” ICLR, 2015
- [3] A. Antoniou et al., “How to Train Your MAML,” ICLR, 2019