

메타러닝 학습에서의 학습순서에 관한 연구

송원근*, 이정우
서울대학교, 서울대학교

*swg0110@cml.snu.ac.kr, junglee@snu.ac.kr

A Study of task ordering method for Meta-learning

Wongeun Song*, Jungwoo Lee
*Seoul National Univ., Seoul National Univ.

요약

본 논문에서는 깊은 신경망 모델을 통해 학습을 하는 방법을 학습하여서 새로운 문제에 대해서 빠른 학습을 목표로 하는 **Meta-learning** 모델을 더 효율적으로 학습시키는 방법에 대해서 연구하였다. 기존의 **Meta-Learning** 방법들은 모두 학습순서에 대해서 신경을 쓰지 않지만 일반적인 딥러닝 학습에서도 순서는 중요한 것으로 알려져 있다. 그래서 우리는 각각의 **task**의 어려움 정도를 추정하고 추정값을 가지고 학습에 쓰일 문제들을 샘플링하는 과정을 연속적으로 변화시키는 방법에 대해서 제안하였다. 해당 방법은 **Meta learning** 방법중에 하나인 **MAML** 데이터에 대해서 실험을 하였고 해당 방법이 성능을 증가시킨다는 것을 확인하였다.

I. 서론

깊은신경망모형은 처음 제안된 이후로 다양한 분야에서 적용되어서 사람수준 혹은 사람 수준 이상의 성능을 보여주고 있다. 이미지 분류에 대해서도 다양한 구조들이 제안이 되어왔고, 강화학습 방법에서도 다양한 방법이 제안이 되어서 이미 사람을 뛰어 넘는 수준의 결과들을 보여줘왔다.

그러나 딥러닝 모델의 오류 함수는 매우 불룩하지 않은 특성을 가지고 있어서 최적화를 시키기에 어려운 것으로 악명이 높다. 그래서 해당 함수에 대한 최적화를 진행하기 위해서 학습에 사용되는 데이터의 순서를 고려를 한다거나 학습과정에서 임의로 부분적으로 가지치기를 하여서 일반화를 잘 시키도록 하여서 학습의 성능을 높인다거나 하는 방법들이 많이 제안이 되었다.

다른 한 편으로는 딥러닝 모델은 하나의 일에 대해서 학습을 시키기 위해서는 엄청나게 많은 양의 데이터가 필요하다는 문제가 존재하여왔다. 이는 작은 규모의 사업장이나 이런 분야의 전문인력이 존재하지 않은 사업장에서는 딥러닝 모델을 적용하는데 한계점을 가지게 하는 중요한 요인으로 작용하여왔다. 따라서 이를 해결하기 위해서 **Meta-Learning**이라는 방법으로 해당 문제를 해결하고자 하는 시도들이 다양하게 있어왔다.

Meta Learning이라는 방법은 크게 보면 새로운 일을 배우는 방법에 대해서 학습을 하겠다는 것을 기본적인 틀로 가지고 있다. 해당 방법은 사람의 학습과정에서 직관을 얻어서 제안이 된 방법이다. 사람은 새로운 일에 대해서 학습을 할 때 완전히 처음부터 새롭게 학습을 하지 않는다. 사람은 이전에 경험한 것들중에 비슷한 경험들을 활용하여 새로운 학습을 진행하게 된다. 그런데 깊은 신경망 모형은 처음 학습을 진행할 때 완전히 임의로 초기화를 진행을 한 후에 학습을 시작하기 때문에 이런 비효율적인 부분에 사람의 학습과정을 따라서 더 적은 데이터로 학습이 가능하게 하는 방법이다.

두 문제 모두 깊은 신경망의 문제점을 해결하는데 많은 성과를 내왔고 계속 발전중인 분야이지만 해당 방법들은 서로 적용점을 찾지 못하고 있어왔다. 그래서 **Meta learning** 방법에서는 학습에 사용될 일들을 모두 똑같은 확률을 주고 무작위로 추출하였다. 따라서 우리는 이런 문제를 해결하기 위해 순서고려 방법을 제안한다. 우리가 대상으로 하는 문제는 **Few shot** 분류문제이며 이는 학습의 대상이 되는 각각의 일들이 분류문제이고 적은양의 데이터만을 이용해서 학습을 하는 것을 의미한다.

II. 본론

제안 방법

그래서 우리가 제안하는 방법은 학습과정중에서 관측한 결과를 가지고 범주 사이의 비슷함을 추정하는 과정과 추정된 결과를 가지고 샘플러를 만들어서 샘플링을 진행하는 과정으로 나뉜다.

먼저 본 논문에서는 범주 사이의 비슷한 정도라는 것을 해당 범주 두 가지 만을 가지고 비교하는 일을 했을 때 모델이 느끼는 어려움 정도라고 정의하였다. 그래서 해당 값을 추정하기 위해서 학습과정에서 해당 클래스들에 대해서 **softmax**를 거치지 않은, 정규화 되지 않은 값들을 이용하여 마치 두개의 범주만을 가지고 학습할 때 나오는 결과인것처럼 취급하여 해당값을 추정하였다.

그리고 해당 값을 이용하여 각각의 일의 어려움에 대해서 추정하는데에도 사용하였다. 각각 일의 어려움은 그 일에 속한 이미지 범주 사이의 어려움 정도를 모두 더한 것이라고 정의를 하였다. 그리고 해당 일이 선택이 될 확률이 그 값에 비례하게 되도록 정의를 하였다. 그래서 각각의 확률이 그 어려움에 자연상수의 지수에 비례하도록 정의를 하였다.

이런 확률 분포에 대해서 샘플링을 하기위해서 우리는 순차적인 샘플링방법을 사용하였다. 우리가 추출하려는 일을 고르려면 전체 범주중에서 우리가 원하는 개수만큼을 뽑아야 되므로 해당 방법을 수행하기 위해서는 지수적인 계산량이 필요로 한다. 그래서 우리는 이를 근사하여서 순차적으로 클래스를 추출하였다. 즉 **n**개를 **sampling**하기 위해서 한 개를 뽑고 그것에 대한 사후확률을 구해서

다음것을 뽑고 또 사후확률을 구해서 다음것을 뽑는 방법을 사용하였다.

실험

본 논문에서는 Meta learning을 학습방법으로 처음 제안된 이후에 가장 많이 사용이 되고 있는 MAML이란 방법에 학습순서를 적용해서 실험을 진행하였다. 해당 방법은 Mini Imagenet이라는 데이터셋에 대해서 실험을 진행하였다.

Mini Imagenet은 600개의 가지수로 이루어진 데이터로 각각이 20개의 이미지를 가지고 있다 우리는 여기에서 20개씩의 범주를 뽑아서 20가지로 분류하는 일을 만들고 이에 대해서 학습을 진행하였다. 첫 번째로는 각각의 범주에 하나의 이미지 만을 가지고 학습을 진행하게 하는 설정에 대해서 실험을 하였고 그 다음에는 각각의 범주에 5개 씩의 이미지, 즉, 한 가지 일에 100장의 이미지를 가지고 학습을 시키는 설정에 대해서 실험을 진행하였다.

	20w1s	20w5s
MAML	0.1655	0.2717
MAML (순서고려)	0.166	0.2885

그리고 실험결과와 위와 같다 위의 실험에서 확인 할 수 있듯이 MAML만을 사용했을 때에는 20 범주를 각각 한가지 이미지만 가지고 학습하는 경우에 대해서는 0.1655의 정확도 5개를 가지고 학습하는 경우에는 0.2717이라는 정확도를 보였다. 그리고 순서를 고려해서 학습을 진행하는 경우에는 0.166과 0.2885의 값을 가지는 것을 확인하였다. 정확도만을 보았을 때는 큰 변화가 없다고 생각이 될 지 모르지만 12000개의 이미지의 1퍼센트가 120개라는 것과 실제 환경에서 수만장의 이미지에 대해서 사용이 되었을때는 수백개가량의 이미지에 대해서 더 정확한 분류를 할 수 있게 되었다는 것을 의미하는 것으로 실제의 경우에는 큰 변화를 가져올 수 있다고 할 수 있다.

III. 결론

본논문에서는 깊은인공신경망 모형에게 새로운 일을 학습방법을 가르치게 하는 Meta-Learning을 더 효율적으로 학습시키는 방법에 대해서 연구하였다. 해당 연구에서는 분류의 수에 따라 지수적으로 많은 수가 존재하는 일들에 대한 어려움을 분류의 수의 제곱의 계산과 메모리만을 가지고 추정하는 방법을 제안하였고, 지수적으로 많은 수에 대해서 제곱의 계산 자원만을 활용하여 추출하는 방법에 대해서 제안하였다. 해당 방법은 이 문제에 대해서 가장 많이 검증에 사용되는 Mini Imagenet 데이터와 가장 많이 사용되는 알고리즘인 MAML에 대해서 적용되어 검증하였다. 해당 방법을 MAML에 적용한 결과 성능 향상이 존재함을 실험적으로도 확인하였다.

ACKNOWLEDGMENT

This work is in part supported by National Research Foundation of Korea (NRF) grant funded by the Korea government(MSIT) (2021R1A4A1030898), Bio-Mimetic Robot Research Center Funded by Defense Acquisition Program Administration, Agency for Defense Development (UD190018ID), INMAC, and BK21-plus.

참 고 문 헌

- [1] John Schulman, Sergey Levine, Philipp Moritz, Michael Jordan, and Pieter Abbeel. Trust Region 188 Policy Optimization. In ICML, 2015
- [2] Timothy P. Lillicrap, Jonathan J. Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, and Daan Wierstra. Continuous control with deep reinforcement learning. In ICLR, 2016.
- [3] John Schulman, Filip Wolski, Prafulla Dhariwal, Alec Radford, and Oleg Klimov. Proxima Policy Optimization Algorithms. arXiv preprint arXiv:1707.06347, 2017.
- [4] Scott Fujimoto, Herke van Hoof, and David Meger. Addressing Function Approximation Error in 195 Actor-Critic Methods. In ICML, 2018 196
- [5] Tuomas Haarnoja, Aurick Zhou, Pieter Abbeel, and Sergey Levine. Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor. In ICML, 2018
- [6] Karen Simonyan, and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556, 2014