

지속학습을 위한 경로 선택 모델

전재현¹, 장병탁^{1,2,3}

¹서울대학교 협동과정 뇌과학전공, ²서울대학교 컴퓨터공학부, ³써로마인드 로보틱스

{jhjun, btzhang}@bi.snu.ac.kr

Selective Pathway Model for Continual Learning

Jaehyun Jun¹, Byoung-Tak Zhang^{1,2,3}

¹Interdisciplinary Program in Neuroscience, Seoul National University

²Department of Computer Science and Engineering, Seoul National University

³Surromind Robotics

요 약

인간과 동등한 수준의 범용 인공지능으로 발돋움 하기 위해서는 다양한 업무(Task)를 학습하고 수행할 수 있는 지속학습 (Continual Learning) 문제가 필수적이다. 전이학습을 통해서 이전의 비슷한 문제에 대해서는 업무를 최대한으로 잊어 버리지 않도록 학습하는 방식들이 여럿 나왔다. 하지만 전이학습을 하더라도 업무들마다 다른 부분이 존재하기 때문에, 하나의 동일한 인공신경망으로 모든 업무를 학습시키는 방법에는 성능 손실이 있을 수 밖에 없다. 이 한계를 해결하기 위해 신경망의 학습 경로를 공유하는 부분과 다르게 가져가는 부분으로 나눠서 업무마다 다른 경로를 통해 학습할 수 있도록 하는 모델을 제안한다. 이렇게 했을 때 공유하는 부분은 전이학습을 통해 학습이 되고 독립적으로 구성된 부분은 해당 업무 특성에 맞게 학습이 되는 것을 기대해 볼 수 있다. 실험을 통해 기본적인 전이학습보다 향상된 성능을 확인 할 수 있으며 타 전이학습 방법과 같이 사용할 수 있는 확장성을 제공한다. 실험은 Permuted MNIST dataset을 사용하여 3개의 문제를 전이 학습으로 학습하였다.

1. 서 론

현재 대부분의 인공지능 연구는 한 가지의 업무(Task)를 수행하는 연구가 위주로 진행이 되어왔다. 하지만 범용 인공지능으로 인간과 동등한 역할을 수행하기 위해서는 여러 업무를 수행할 수 있어야 하며, 유사한 업무 간에는 상호작용을 통해 시너지 효과를 얻을 수 있어야 한다. 그래서 비슷한 역할을 수행하는 다중 업무 (Multi-task) 학습을 통해 서로 시너지 효과를 얻는 연구도 많이 진행 되고 있으며 [1], 여러 업무를 순차적으로 학습하여 이전 학습을 최대한 잊어버리지 않도록 학습 하는 지속학습 (Continual Learning) 연구들이 진행 되어왔다 [2].

새로운 업무를 학습 할 때 이전 업무의 파라미터 방향으로 L2-regularization을 주는 L2-transfer와 drop ratio를 통해 원점으로부터 혹은 이전 업무의 파라미터로부터 학습을 결정하는 Drop-transfer 방식의 연구가 있다 [2]. 이 방식들은 학습을 함에 따라 오래된 업무일수록 더 잘 잊어 버리는 catastrophic forgetting 문제가 있다. 이 문제를 해결하기 위해서 업무 별 파라미터 들의 기하학적 특징을 찾아 여러 업무들이 수행되는 파라미터들의 분포도가 교차되는 위치를 계산하는 Weight-transfer 방식이 있다 [2].

하지만 이 방법은 모든 업무에 따른 모든 신경망을 저장하고 있어야 하기 때문에, 업무 수에 비례하여 큰 저장공간이 필요하다는 단점이 있다.

뇌 과학 적인 측면에 봤을 때 두뇌는 여러 업무를 학습한다고 해서 두뇌가 더 커지는 구조가 아닌 단일한 신경망 구조체에서 여러 업무가 동일하게 학습 할 수 있도록 업무 별로 신경 활성화 경로를 구성한다. 유사한 업무의 경우 활성화 경로가 유사하게 흐른다 [3]. 이와 같은 측면에서 봤을 때 특성이 다른 업무를 수행하려면 인공신경망도 어느정도 활성화 경로를 다르게 가져가야 할 필요성이 있다.

네트워크를 구성할 때 하나의 큰 인공 신경망이 존재 하고 업무마다 활성화 경로를 선택적으로 가져가게 된다면, 업무 특성에 맞게 개별로 학습이 될 수 있도록 독립적인 경로도 구성할 수 있을 것이다. 또, 어느 정도 파라미터를 공유하여 공통적인 역할을 수행할 수 있는 신경망 부분도 같이 구성해 볼 수 있다. 업무의 동일한 특성에 대해서는 공유된 파라미터에서 학습을 하게 되고 업무별로 특화 되어있는 기능들은 독립적인 파라미터에서 학습하는 것을 기대해 볼 수 있다.

본 논문에서 제시하는 방법은 기존에 제시된 전이 학습 방법과 같이 사용했을 때 더 나은 성능을 기대해 볼 수 있다. 특성이 유사한 업무 뿐만 아니라 어느정도

특성이 다른 업무들을 학습 했을 때도 나은 성능을 기대해 볼 수 있다.




그림 1 인공 신경망 경로 선택 방식

2. 경로 선택 모델

본 논문에서는 인공신경망에서 공통적인 기능을 하는 공유 노드와 특정 업무를 수행하는 선택 노드로 나누어 업무마다 경로를 다르게 선택하는 모델을 제안한다. 공유 노드는 유사한 업무들끼리 공통되는 기능을 수행하는 노드이고, 선택 노드는 업무에 특정한 기능을 수행할 수 있도록 구성한 노드이다.

[그림 1]로 2층의 다계층 퍼셉트론(MLP)을 모델을 이용해 간략하게 생각해 볼 수 있다. MLP의 은닉층에서 파랑색으로 표시된 노드는 공유 노드이며, 이것은 인공신경망을 초기화할 때 선택한다. 그리고 빨강색 노드는 업무마다 임의로 다른 노드를 선택하도록 만든 선택 노드이다. 임의로 선택하여 선택 노드끼리 겹치는 노드가 발생 할 수 있도록 만든 이유는 모든 업무가 아닌 일부 업무끼리 만 공통적으로 수행해야하는 기능이 있을 수도 있기 때문에 선택 노드를 완전히 독립적으로 두지 않았다. [그림 1]은 2층의 MLP로 가장 단순한 형태에서 설명을 했지만 더 복잡한 인공신경망에서는 은닉층에서만 공통 노드와 선택 노드를 나눈다고 생각하면 된다.

본 모델이 제시하는 장점은 두 가지가 있다. 첫째, 다중 업무를 수행할 때 모든 업무의 파라미터의 분포도가 교차지점이 존재해야 하는 기존 모델들의 한계를 극복할 수 있다. 둘째, 기존 전이학습 방식에 추가적으로 적용할 수 있어 성능을 더욱 향상시킬 수 있다.

이 모델은 업무마다 신경망이 새로 생성되는 것이 아니라, 하나의 큰 인공신경망 안에서 업무별로 경로를 선택하는 것이다. 온전한 하나의 전체 신경망이 존재하기 때문에 기존의 Drop-transfer 나 L2-transfer 등 다양한 전이학습 방식과 결합하여 사용할 수 있다.

3. 실험

3.1 데이터 및 실험

실험에서는 지속학습에서 일반적으로 사용하는 Permuted MNIST 데이터로 진행하였다 [4,5]. MNIST 데이터는 숫자 이미지를 구별하는 데이터로, Permuted MNIST는 MNIST 데이터를 임의의 순서로 재배치한 이미지로 구성된 데이터이다. 재배치할 때는 업무 별 재배치 순서가 고정되어 있으나 업무마다 다른 순서로 이미지를 재배치하게 된다. 본 논문은 3개의 업무를 기준으로 실험을 하였다. 첫번째 업무는 보통의 MNIST 이미지를 구별하는 작업을 수행하며, 두번째, 세번째 업무는 재배치된 MNIST 이미지를 구별하는 작업을 수행한다. 이렇게 서로 다른 이미지를 통해 숫자를 구별하는 것은 같은 문제를 다른 데이터로 해결하는 문제 설정이다.

기준 모델은 3층의 MLP (786→800→800→10)와 dropout, ReLU 활성화함수[6]로 구성하였으며 단일 업무로 학습 시켰을 경우 test 데이터에 대해서 98.3%의 성능을 낼 수 있는 모델이다. 실험은 공유 비율을 바꾸면서 선택 노드를 절반 선택할 수 있도록 전체 인공신경망 크기를 조절했다. 예를 들어 공유도가 0.5이면 전체 신경망을 786→1200→1200→10 로 구성하고 은닉층에서 1200개 파라미터 중 400개는 공유 파라미터로 사용하고 나머지 800개 중에 400개를 임의로 선택할 수 있도록 했다. 결국 공유 파라미터와 선택 파라미터로 구성된 신경망이 786→800→800→10 크기를 갖게 된다. 최적화 알고리즘은 가장 기본적인 방식인 Stochastic Gradient Descent (SGD) 를 사용했다. 실험을 통해 Permuted MNIST 문제에서 가장 최적화 된 공유비율을 찾았고 성능 향상 정도를 알아보았다.

3.2 실험 결과

기준 모델은 SGD 알고리즘을 이용해 단일 모델(786→800→800→10)에 모든 업무를 순차적으로 학습시킨 방식을 사용하고, [표 1]에서 “SGD”로 표현한다. [표 1]에서 나타난 기준 모델은 특징 차이가 있는 업무를 모두 같은 신경망을 통해 학습 하기 때문에 학습 할수록 이전 업무에 대한 내용을 까먹는 현상을 볼 수 있다. 현재는 3개의 업무를 기준으로 실험을 해 보았지만 업무의 수가 증가 할수록 이전 업무를 잊어버리는 비율은 더 크게 상승한다. 반면에 경로 선택 모델은 기준 모델에 비해서 첫번째 업무에 대한 성능을 19.1% 가량 향상시킴으로써 비교적 덜 잊는다고 말할 수 있다.

표 1 기준 모델과 정확도 비교

	Task 1	Task 2	Task 3	All Task
SGD	67.22	95.07	98.38	86.89

Selective	86.37	93.31	97.81	92.50
-----------	-------	-------	-------	-------

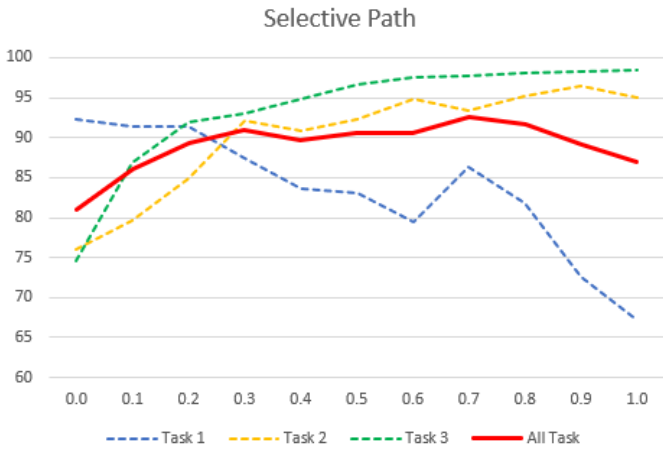


그림 2 공유 비율에 따른 성능

[그림 2]는 공유 비율에 따른 경로 선택 모델의 성능을 보여주는 그래프이다. 경로 선택 모델 (Selective)에서 공유 비율이 1.0 값을 가질 때는 모든 파라미터를 공유한다는 의미이므로 SGD 방식과 동일하다. 이것은 일반적인 네트워크를 SGD로 순차적 학습하는 것과 동일하다. 공유 비율을 0.7로 지정 했을 때 가장 판별 정확도가 높았다. 이것은 70% 정도의 노드를 업무의 공통 기능으로 지정했을 때 성능이 가장 좋았다는 것을 의미한다. 이것은 업무들 간의 유사도가 높음을 어느정도 나타내는 결과로 볼 수 있다. 또한 공유를 높일수록 오래 지난 업무에 대한 성능이 크게 손실된다는 것도 확인할 수 있다. 공유 비율이 0.0 값을 가지는 것은 모든 은닉층을 임의로 선택한다는 의미로 대부분의 노드를 업무별로 구분하는 모델이다. 이 때는 이전 업무에 대한 성능 소실은 적지만 이후 업무에 대한 학습이 잘 이뤄지지 않고 있음을 알 수 있다.

4. 결론

본 논문은 하나의 네트워크를 업무마다 다른 경로를 선택하여 학습하는 방법을 제안했다. 이것은 여러 업무를 지속학습을 통해 학습했을 때 이전 업무를 잊는 catastrophic forgetting 문제를 완화시키기 위한 해결법을 제시한 것이다. 단일 모델로 연속적으로 학습하는 기존 모델보다 이전 업무를 덜 잊어버리는 것을 확인 했고 결과적으로 전체 업무에 대한 정확도 역시 향상 됨을 실험으로 보여주었다.

기존 방법들은 동일한 파라미터로 학습을 하기 때문에 각 업무에 해당하는 파라미터의 분포도가 어느정도 겹치게 존재해야만 다중업무 학습의 성능이 어느정도 나오기 때문에 업무가 어느정도 차이가 나는

데이터에 대해서는 잘 수행하지 못하는 문제점이 있다. 하지만 본 논문의 방식은 업무 별로 경로를 다르게 설정 하기 때문에 어느정도 차이가 있는 업무에 대해서도 수행을 잘 할 수 있을 것이다.

또, 단일한 모델을 활용한 접근 방식이기 때문에 다른 전이 학습을 병행하여 사용할 수 있는 확장성도 가지고 있다. 현 실험에서 기존의 전이학습 방식을 추가하면 실험하면 성능이 더 향상될 것을 기대한다.

본 논문에서는 지속학습의 가장 단순한 형태인 Permuted MNIST 문제에만 적용하여 평가하였지만 더욱 복잡한 모델에서 성능을 비교해서 좀 더 일반화된 평가를 진행해 볼 필요가 있다. 향후 다른 파라미터 분포도를 가지고있는 다중 업무를 다뤄, 경로 선택 방식을 일반화 시킬 수 있도록 폭 넓은 평가를 진행해 볼 예정이다.

감사의 글

이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터(R0126-16-1072-SW스타랩, 2017-0-01772-VTT, 2018-0-00622-RMI), 한국산업기술평가관리원(10060086-RISF)의 지원을 받았음.

참고 문헌

- [1] Jifeng Dai, Kaiming He, and Jian Sun. "Instance-aware semantic segmentation via multi-task network cascades." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016.
- [2] Sang-Woo Lee, et al. "Overcoming catastrophic forgetting by incremental moment matching." Advances in Neural Information Processing Systems. 2017.
- [3] Kandel, Eric R., James H. 1932- Schwartz, and Thomas M. Jessell. "Principles of Neural Science". 5th ed. New York: McGraw-Hill, Health Professions Division, 2014.
- [4] Ian J Goodfellow, Mehdi Mirza, Da Xiao, Aaron Courville, and Yoshua Bengio. "An empirical investigation of catastrophic forgetting in gradient-based neural networks". arXiv preprint arXiv:1312.6211, 2013.
- [5] Kirkpatrick, James, et al. "Overcoming catastrophic forgetting in neural networks." Proceedings of the National Academy of Sciences 114.13 (2017): 3521-3526.
- [6] Nair, Vinod, and Geoffrey E. Hinton. "Rectified linear units improve restricted boltzmann machines." Proceedings of the 27th international conference on machine learning (ICML-10). 2010.