

랜덤 가중치를 가지는 오류 역전파 학습의 성능 분석

이소하, 박혜영

경북대학교 컴퓨터학부

kiyo91012@gmail.com, hypark@knu.ac.kr

Analysis on the Performance of Error Backpropagation Learning with Random Weights

Lee Soha, Park Hyeyoung

School of Computer Science and Engineering, KyungPook National Univ.

요약

인공신경망의 학습을 위해 제안된 오류 역전파 알고리즘은 최근까지도 딥러닝 모델 핵심 학습 알고리즘으로 사용되고 있다. 하지만 오류 역전파 학습법에서 최상위층의 오류 신호가 가중치를 따라 하위층으로 순차적으로 전달되는 가중치 전송(weight transport)방식에 대해 정보 전달의 효율성과 생물학적 타당성에 대한 논의는 계속되어왔다. 그 대안을 찾는 연구의 하나로, 역방향 오류 신호 전달 과정에서 랜덤 가중치를 이용하는 알고리즘들이 최근에 제안되었다. 이러한 방법들은 간단한 딥러닝 모델을 사용하여 실험을 통해 그 가능성을 입증하였으나, 아직 실험 초기 단계에 머물고 있다. 본 논문은 랜덤 가중치 학습법에 다양한 랜덤 가중치 생성 방식을 결합하였을 때 그 성능 변화에 대하여 실험을 통해 분석한다.

1. 서론

인공신경망들은 최근 다양한 응용 분야에서 성공적으로 사용되고 있으며 이런 인공신경망을 학습시키는 알고리즘인 오류역전파(Backpropagation, BP) 학습법은 개발된 이후 현재까지 대부분의 딥러닝 모델 학습에 활용되고 있다[1]. 오류 역전파 알고리즘의 학습은 하위층의 가중치를 수정하기 위해 상위층들의 가중치 값을 활용하여 오류 신호를 순차적으로 전달받으면서 수행된다. 이런 오류 역전파 알고리즘의 역전파를 통한 오류 기반 학습 특성 때문에 가중치 전송(weight transport) 문제와 같은 정보 전달의 비효율성과 생물학적 타당성 결여와 같은 한계가 존재한다[2]. 특히 출력값을 계산하는 순방향 가중치 값이 오류 신호를 전달하는 역방향 계산에서도 동일하게 사용되는 가중치 대칭(weight symmetry)의 특성은 실제 뇌에서 일어나는 정보 전달 방식이라고 보기 힘들며, 이를 해결하기 위한 시도들이 이뤄지고 있다[2-5].

피드백 할당(feedback alignment, FA) 알고리즘은 역방향 오류 신호 전달 단계에서 순방향 가중치에 의존하지 않고 고정된 랜덤 가중치를 사용하여 네트워크의 학습을 수행하는데 오류 역전파 알고리즘과 비교하였을 때 충분히 비슷한 학습 성과를 낼 수 있음을 확인할 수 있었다[2]. 피드백 할당 알고리즘을 확장하여 학습 병렬 처리를 통한 정보 전달의 효율성 측면에서 그 가능성을 확인한 직접 피드백 할당(direct feedback alignment, DFA) 알고리즘과 스파스 연결을 직접 피드백 할당 알고리즘에 결합하여 학습 중 계산 복잡성을 개선한 알고리즘도 제안되었다[3, 4]. 한편 가중치 대칭성의 문제를 완화하는 또 다른 방법으로 순방향 가중치와 부호만 일치시킨 랜덤 가중치를 사용하는 부호 대칭(sign symmetry, SS) 알고리즘이 제안되어, 역방향 학습에서 가중치의 크기는 성능에 영향을 크게 미치지 않음과 부호 일치성이 학습에 중요한 역할을 함을 증명하였다[5].

그러나 이러한 역방향 랜덤 가중치를 이용하는 연구들은 아직 초기 단계로 비교적 간단한 실험 결과만을 제시하고 있어, 그 특성을 이해하기 위해서는 보다 많은 분석이 필요하다. 본 연구에서는 피드백 할당 알고리즘에서 역방향 랜덤 가중치를 생성할 때 각 층의 가중치 사이 관계를 고려하여 다양한 가중치 생성 방법 [6-8]을 적용하여 그 효과를 분석한다. 기존의 피드백 할당 알고리즘에서는 역방향 랜덤 가중치를 생성할 때 카이밍 균등 분포 초기화 방법을 적용하였지만 본 연구에서는 [6-8]과 같은 연구를 활용하여 역방향 가중치의 랜덤 샘플링 방식이 학습 성능에 미치는 영향에 대해서 분석한다.

이 논문의 구성은 다음과 같다. 2에서는 FA 방법의 설명과 학습 성능 향상을 위한 학습 전략 제안, 3절에서는 실험 결과를 제시한 후 4절에서는 결론과 향후 연구 계획에 대하여 설명한다.

II. 랜덤 가중치를 가지는 학습법을 이용한 학습 성능 개선 전략

2.1. 랜덤가중치이용한학습알고리즘

먼저 기본적인 오류 역전파 학습법(backpropagation, BP)에 대하여 기술한 후, 이로부터 변형된 랜덤 가중치 학습법에 대하여 기술한다. 설명의 편의성을 위해 다층 퍼셉트론을 기반으로 설명하나, 합성곱 신경망 등의 다른 모델들도 같은 방식으로 적용된다. l 번째 층의 i 번째 노드의 출력 $X_i^{(l)}$ 는 $l-1$ 번째 층의 k 번째 노드의 출력 $X_k^{(l-1)}$ 와 이들을 연결하는 가중치 $W_{ki}^{(l)}$, i 번째 노드로 들어오는 입력들의 가중합 U_i 와 활성화 함수 $f(\cdot)$ 에 의해 다음과 같이 계산된다.

$$X_i^{(l)} = f(U_i^{(l)}), \quad U_i^{(l)} = \sum_k W_{ki}^{(l)} X_k^{(l-1)} \quad (1)$$

순방향 계산 과정에서 입력층에서 출력층으로 순차적으로 노드들의 출력값이 계산되면, 신경망의 최종 출력에 대하여 오차값 E

가 얻어진다. 이 오류를 감소시키기 위한 오류 역전과 학습법을 적용하면, 노드($X_i^{(l)}$)에서의 오류 신호는 다음과 같이 상위층의 역전과 신호를 이용하여 계산된다.

$$\frac{\partial E}{\partial X_i^{(l)}} = \sum_j W_{ij}^{(l+1)} f'(U_j^{(l+1)}) \frac{\partial E}{\partial X_j^{(l+1)}} \quad (2)$$

이 식에서 순방향 계산에 사용되는 가중치 $W_{ij}^{(l+1)}$ 값이 그대로 적용되는 가중치 대칭 문제가 존재함을 알 수 있다. 이 오류 신호를 이용한 가중치 수정 식은 다음과 같이 얻어진다.

$$\frac{\partial E}{\partial W_{ki}^{(l)}} = \frac{\partial E}{\partial X_i^{(l)}} f'(U_i^{(l)}) X_k^{(l-1)} \quad (3)$$

$$W_{ki}^{(l)} = W_{ki}^{(l)} - \eta \frac{\partial E}{\partial W_{ki}^{(l)}} \quad (4)$$

랜덤 가중치를 이용한 학습 알고리즘[2-5]들은 역방향 계산을 수행시에 순방향 가중치 W 대신 랜덤 가중치 V 를 적용한다. 즉, 노드($X_i^{(l)}$)에서의 오류 신호는 다음과 같이 계산된다.

$$\frac{\partial E}{\partial X_i^{(l)}} = \sum_j V_{ij}^{(l+1)} f'(U_j^{(l+1)}) \frac{\partial E}{\partial X_j^{(l+1)}} \quad (5)$$

오류 역전과 이론과 달리, 이러한 방법들은 순방향 가중치(W)와 역방향 가중치(V)가 같을 필요가 없으며, 학습시에 각 노드는 상위층의 가중치 정보를 계속 유지할 필요가 없다. 이러한 방식을 신경망 학습에 처음 적용한 피드백 할당(FA) 알고리즘[2]에서는 랜덤하게 선택한 V 를 그대로 학습에 적용하였으며, 이를 통해서도 오류역전과 학습법과 유사한 성능을 얻을 수 있음을 보였다.

기존의 랜덤 가중치를 이용한 학습 연구들에서는 가중치 생성 방법에 대해서는 별도로 고려하지 않고 기본적인 카이밍 균등 분포 방법과 같은 특정 방법으로 고정한 분석을 수행하였다. 그러나 앞에서 기술한 바와 같이, 랜덤 가중치를 생성하는 방식과 초기 가중치와 학습 동적 특성 간의 관계를 통해 랜덤 가중치를 이용하는 알고리즘의 성능을 보완할 수 있을 것이라 기대되며 이러한 효과를 실험적으로 분석할 필요가 있다. 본 연구에서는 이를 위해 피드백 할당 알고리즘에 가중치 생성 방법을 결합한 학습 전략들에 대하여 정리하고 분석하고자 한다.

2.2. 역방향 랜덤 가중치의 설정

여기서는 다양한 가중치 초기화 방법을 역방향 가중치 초기화에 적용하여 그 성능을 분석한다. 인공신경망에서 순방향 가중치(W)를 생성할 때 같은 크기의 랜덤 가중치(V)를 생성하고 이러한 랜덤 가중치 생성에 여러 가중치 초기화 방법을 적용한다. 첫 번째, 기존 방법인 카이밍 균등 분포 초기화 방법[6]을 사용하면 활성화 함수에 따라 범위를 계산하고 이 범위 내에서 랜덤 가중치 텐서들이 균등하게 생성된다. 두 번째로, 직교 가중치 초기화 방법[7]을 통해 직교 가중치 텐서들로 랜덤 가중치 행렬을 생성하면 정방 행렬이 아닌 경우 차원이 큰 쪽으로 벡터 직교가 성립하게끔 생성된다. 세 번째, 희소 초기화 방법[8]은 가중치 텐서의 크기를 받아와서 먼저 정규 분포로 생성된 난수를 채운 후에 열의 수 만큼 임의의 위치에 원소들을 0으로 변환시켜 희소 초기화 텐서를 생성한다.

본 논문에서는 단순히 하나의 가중치 초기화 방법을 이용하여 성능 향상을 노리는 것 외에 입력층과 은닉층에서 직교 초기화

방법을 사용하고 은닉층과 출력층 사이에는 카이밍 균등 분포나 희소 초기화 방법을 사용한 가중치 초기화 방법을 제안한다. 출력층에서 은닉층으로의 가중치 사이 차이가 클수록 성능에 영향이 있다는 연구[9]에 기반하여, 벡터 공간에서는 직교할 때 차이가 가장 크고 또 역전과의 방향성에 따른 직교를 성립시키기 위해 출력층을 제외한 은닉층의 가중치 설정에 직교 초기화 방법을 적용하였다. 역시 가중치 직교 방향을 유지하기 위해 마지막 은닉층과 출력층의 사이 가중치 설정은 다른 초기화 방법으로 카이밍 균등 분포 초기화와 희소 초기화 방법을 적용하였다.

다음 절에서는 랜덤 가중치를 이용한 학습 방법에 가중치 초기화 방법을 다르게 주었을 경우 어떤 효과가 있는지 실험을 통해 분석하고 이를 바탕으로 효과적인 랜덤 가중치 학습 전략을 제안한다.

III. 실험 분석

3.1. 실험 조건

랜덤 가중치 설정 방법에 따른 학습 효과를 확인하기 위하여 MNIST 데이터 세트를 이용하여 다층 퍼셉트론과 합성곱 신경망 구조에 대한 학습 실험을 수행하였다. 학습 에포크는 100번을 수행하였으며 학습률은 0.0001로 설정하였다. 실험에서 사용한 모델은 다층 퍼셉트론 네트워크에서는 완전 연결 층이 1개부터 4개까지의 경우가 있으며 합성곱 신경망 모델은 합성곱 블록이 1개부터 2개인 경우로 구성하였다. 모든 실험의 오차 함수로는 크로스 엔트로피 함수를 사용하였으며 활성화 함수는 하이퍼 탄젠트 함수를 사용하였고 최적화 알고리즘으로는 Adam을 사용하였다. 실험 결과는 테스트 오차를 백분율로 나타냈으며 각 학습 시도에서 가장 낮은 테스트 오차율을 집계하였고, 초기 가중치를 달리 하는 10번의 실험에 대한 평균과 표준편차를 얻었다.

랜덤 가중치 설정 방법에 카이밍 균등 분포 초기화 방법을 사용한 FA 방법을 UFA라 명명하였다. 다음으로 직교 초기화 방법을 사용한 FA 방법은 OFA 그리고 이 논문에서 제안한 학습 전략으로 직교 초기화 방법을 은닉층 역전과 가중치에 사용하고 마지막 출력층에 대해 균등 분포와 희소 초기화 방법을 사용한 것을 각각 OUFA와 OSFA로 명명하였다.

3.2. 실험 결과

MNIST 데이터 세트에서 각 가중치 초기화 방법을 랜덤 가중치 설정에 적용하여 학습한 성능을 [표 1]에 비교 정리하였다. 각 모델 구조에서 가장 성능이 좋은 결과는 굵은 표시와 밑줄로 표시하였고, 두 번째로 성능이 좋은 가중치 설정 방법은 굵은 글씨로만 표시하였다.

[표 1]에 정리한 것을 살펴보면 신경망 구조가 단순할 때에 각 가중치 설정 방법들의 성능 차이는 크게 보이지 않는 것으로 나타났다. 하지만 전체적으로 봤을 때 구조가 복잡해질수록 직교 초기화와 희소 초기화를 결합한 OSFA와 직교 초기화와 균등 분포 초기화를 결합한 OUFA의 오차율이 낮은 경향을 보이는 것을 확인할 수 있다. 또한 직교 초기화만 사용한 방식인 OFA의 경우에도 오차율이 낮은 경향을 보이는 것을 확인할 수 있다. 이를 통해 직교 초기화 방식과 희소 초기화 방식을 이용하였을 때 노드 간 가중치의 차이를 크게 만들어 랜덤 가중치를 사용하는 학습 알고리즘의 성능 향상을 노릴 수 있다는 가능성을 확인하였다.

[표 1] 랜덤 가중치 설정 방법에 따른 MNIST 성능 비교

가중치 설정 모델	평균 오차율(%)±표준편차			
	UFA	OFA	OUFA	OSFA
FC1-1000	1.75±0.06	1.77±0.04	1.75±0.07	1.75±0.05
FC2-1000	1.67±0.05	1.64±0.05	1.67±0.03	1.62±0.03
FC3-800	1.60±0.06	1.58±0.04	1.58±0.04	1.57±0.05
FC4-800	1.69±0.05	1.65±0.04	1.66±0.04	1.68±0.06
CONV1-5x5	1.24±0.02	1.25±0.04	1.21±0.06	1.23±0.04
CONV2-5x5	0.82±0.06	0.80±0.06	0.76±0.04	0.78±0.06

본 실험에서는 랜덤 가중치 생성 방식을 다양하게 적용하였을 때 그 효과에 대하여 조사하였다. 학습 다이나믹스 측면에서 기존의 균등 분포를 통해 가중치를 생성한 것보다 직교 초기화 방법을 통해 초기 가중치 간 거리를 멀게 하였을 때 성능이 조금 더 향상되는 것을 확인할 수 있었다. 이러한 결과를 바탕으로 랜덤 가중치를 이용한 학습에 적절한 랜덤 가중치 설정 방법을 적용함으로써 가중치 전송 문제를 가지는 기존 BP와 비슷한 성능을 얻을 수 있음을 확인하였다.

IV. 결론

본 논문에서는 오류 역전파 학습법이 가지는 가중치 전송 문제를 해결하기 위해 개발된 랜덤 가중치 학습 알고리즘의 성능에 랜덤 가중치 설정 방법이 미치는 영향을 조사하였다. 기울기 역전파에서 가중치의 관계를 통해 성능을 개선할 수 있다는 점에 착안하여 랜덤 가중치를 설정할 때 다양한 가중치 초기화 방법을 적용하여 그 차이를 분석하였다. 기존 가중치 생성 방법인 균등 분포 초기화 방법을 사용하였을 때 간단한 구조에서는 성능이 가장 좋지만 구조가 복잡해질수록 직교 초기화 방법을 사용하였을 경우가 성능이 더 좋은 것으로 나타났다. 이러한 직교 초기화 방법을 균등 분포 초기화 방법과 희소 초기화 방법에 결합한 방법은 기존의 균등 분포 초기화 방법과 비교하였을 때 더 낮은 학습 오차를 기록하는 등의 성능 개선을 실험을 통해 그 효과를 확인하였다. 향후에는 랜덤 가중치 초기화 설정 시 가중치 벡터 사이의 관계에 대한 심층적 분석과 구현 방법을 모색할 것이다.

ACKNOWLEDGMENT

* 본 연구는 2020년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 에너지인력양성사업으로 지원받아 수행한 인력양성 성과입니다. (No. 20204010600060)

* 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2020R1A2C1010020)

참 고 문 헌

- [1]Rumelhart D.E., Hinton G.E. and Williams R.J., "Learning representations by back-propagating errors", Nature, 323(9):533-536, 1986.
- [2]Lillicrap T.P., Cownden, D., Tweed, D.B. & Akerman, C. J., "Random synaptic feedback weights support error back-propagation for deep learning", Nature Communications, 1-10, 2016.
- [3]Nøkland A., "Direct Feedback Alignment Provides Learning in Deep Neural Networks", 30th Conference on Neural Information Processing Systems, 2016
- [4]Crafton B., Parihar A., Gebhardt E. & Raychowdhury A., "Direct Feedback Alignment With Sparse Connections for Local Learning", Front Neurosci. 2019; 13: 525., 2019.
- [5]Liao Q., Leibo, Z.L. & Poggio, T., "How Important Is Weight Symmetry in Backpropagation?", 30th AAAI Conference on Artificial Intelligence, 2016.
- [6]He K., Zhang X., Ren S. and Sun J., "Delving Deep into rectifiers: Surpassing human-level performance on imagenet classification", In Proceedings of the IEEE international conference on computer vision, 2015.
- [7]Saxe A.M., McClelland J.L. and Ganguli S., "Exact solutions to the nonlinear dynamics of learning in deep linear neural networks", In Proceedings of the Second International Conference on Learning Representations, 2014.
- [8]Martens J., "Deep learning via Hessian-free optimization", Proceedings of the 27th International Conference on Machine Learning, 2010.
- [9]Park H.-Y., Inoue M. and Okada M., "Online learning dynamics of multilayer perceptrons with unidentifiable parameters", Journal of Physics A: Mathematical and General, Vol. 36, pages 11753-11764, 2003.