

# Modular Spiking Neural Networks 의 다중단계 학습알고리즘

이경희\*

\*평택대학교 정보통신학과

khlee@ptu.ac.kr

## Multi-stage Learning for Modular Spiking Neural Networks

Kyunghee Lee\*

\*Dept. of Info. &amp; Comm., PyeongTaek University

### 요약

본 논문에서는 지도학습(Supervised Learning)알고리즘을 사용하는 모듈러 스파이킹 신경회로망(Modular Spiking Neural Networks)에서 학습의 진행 상황에 맞추어 학습용 데이터를 사용하는 다중 단계 학습알고리즘을 제안한다. 또한 컴퓨터 시뮬레이션에 의하여 항공영상 클러스터링 문제에 적용한 결과를 보임으로써 실제적인 문제에서의 적용 타당성과 가능성을 보인다.

### 1. 서론

신경회로망 분야에서 뉴런(Neuron)간의 신호전달을 위한 발화시간의 정보까지 고려하여 시냅스 연결을 모델링하고 있는 스파이크 기반의 신경회로망(Spiking Neural Networks : SNN) 모델에서는 시간에 관련 정보가 전달되도록 한다는 점에서 영상처리 및 패턴인식 등의 분야에서 새로운 능력이 기대되고 있다[1]. 또한 신경회로망의 학습분야에서는 보다 정확한 학습을 위한 단계적인 학습과정의 연구가 있었다[2]. Meftah 등은 영상처리를 위한 단일계층의 SNN 을 제안하였으나 다층구조로의 확장은 어려운 모델이었다[3]. Bohte 등은 다층 SNN 모델에서의 지도학습(Supervised learning)에 대한 연구를 통하여 스파이크(spike)가 발생하는 시각을 이용하여 정보를 전달하고 전달되는 정보의 양에 따라서 다른 계층의 학습도 이루어지는 알고리즘으로서 SpikeProp 알고리즘을 제안하였다[4]. SpikeProp 은 성공적인 알고리즘으로 인정받고 있으나 EBP(Error Back-Propagation)에 근간을 두고 개발되어 EBP 의 약점을 여전히 가지고 있다. 최근 쿠롱에너지 포텐셜(Coulomb Energy Potential)을 가지는 모듈러 SNN 에서의 학습 알고리즘이 제안되어 이러한 EBP 의 약점을 개선하고자 하는 노력이 있었다[5].

본 논문에서는 지도학습 알고리즘을 사용하는 모듈러 SNN 에서 학습이 진행될수록 쉽게 구별되는 데이터를 선택하여 학습하는 다중단계 학습 (Multi-stage Learning)알고리즘을 제안하고, 제안한 알고리즘을 항공영상 클러스터링 문제에 적용하여 기존의 SOM(Self

Organization Map)학습알고리즘의 결과보다 우수함을 보인다.

### 2. 모듈러 SNN 과 다중단계학습(Multi-Stage Learning)

#### 2.1 모듈러 SNN

최근 과학자들은 생물학적 신경회로망의 근본적인 동작과 새로운 신경코드에 관심을 갖기 시작하였으며 그 스파이크 발화 시점들의 타이밍 정보가 중요한 신경코드 역할을 한다는 사실을 발견하였다[1-4]. 모듈러 SNN 에서는 N-차원의 쿠롱에너지 포텐셜에 기초를 두고 M 개의 아이템이 저장되어야 될 특정 위치에 에너지의 최소가 놓이도록 에너지 함수를 식 (2-1)과 같이 정의한다[5].

$$\Psi = \frac{1}{(2L)} \sum_a^M \sum_b^M Q_a Q_b \|x_a - x_b\|^{-L} \quad (2-1)$$

위의 함수에서 적당한 L 을 선택함으로써 저장된 메모리(M) 갯수에 상관없이 입력 아이템( $x_a, x_b$ )은 가장 가까운 메모리에 수렴한다고 알려져 있다. 또한 학습을 위하여 쿠롱에너지의 기울기(Gradient)를 계산하여 의 변화량으로 적용한다[5].

$$\Delta w_{ij}^k = (+)\frac{1}{2} \eta y_i^k(t_j^a) \delta_j^a + (-)\frac{1}{2} \eta y_i^k(t_j^b) \delta_j^b \quad (2-2)$$

#### 2.2 다중단계 학습(Multi-stage Learning) 알고리즘

항공영상은 여러 가지 방법으로 수집한 지구 표면에 대한 이미지 정보로서 이를 활용한 물체의 확인

및 인식은 많은 응용분야에서 중요한 역할을 한다[6]. 영상처리 분야에서 다양한 신경회로망의 적용은 많은 성공을 보이고 있지만 입력영상의 클러스터에 대한 사전 정보들을 수집의 어려움으로 인하여 비지도형 모델(Un-supervised model)인 SOM이 대표적인 모델 중의 하나로 알려져 있다[7]. 지도학습 알고리즘으로서 영상 클러스터링을 위한 모듈러 SNN에서의 다중단계 학습 알고리즘은 다음과 같다.

- Step1) 모듈러 SNN의 학습 파라미터들(가중치, 에포크, 반복횟수 등)의 초기화
- Step2) 영상정보 학습을 위한 RGB 입력벡터로 변환
- Step3) 학습과정을 S 단계로 구분하고, 각 단계별 학습을 위한 입력벡터의 RGB의 범위값 지정
- Step4) 1 단계에서 S 단계까지 단계적으로 아래의 주어진 학습을 실행
  - 4-1) 각 단계에서 주어진 범위값에 해당하는 입력 벡터들을 학습데이터로 선택
  - 4-2) 해당 뉴런들의 시냅스 가중치를 갱신 (식 (2.1)~(2.2)이용).
  - 4-3) 설정한 반복횟수에 도달하거나 수렴이 일어날 때까지 (Step (4-1) ~ Step (4-2))를 반복
- Step5) 출력되는 클러스터의 RGB 값으로 영상을 재구성하여 출력영상으로 새롭게 생성

### 3. 컴퓨터 시뮬레이션

제안한 학습알고리즘의 성능을 확인하기 위하여 항공영상 클러스터링 문제에 대한 컴퓨터 시뮬레이션 결과를 보인다. 학습에 사용한 주요 파라미터로는  $L=2$ , 단계수( $S=3$ ), 클러스터수=5, 학습율=0.000002, 반복횟수=30,000, 가중치의 초기값=0.0~1.0 이고, 실험에 사용한 항공영상은 다음(Daum)의 지도서비스 (<http://map.daum.net>)에서 제공하는 항공영상 중 도로와 건물 그리고 토지 및 숲 등이 포함되어 있는 임의의 도시지역 영상을 선택하였다(그림 1). 학습진행 단계에 따른 학습용 데이터의 선택범위(RGB 값의 범위)의 예를 표 1에 나타낸다.

그림 2(a)는 SOM의 출력결과로 동일 세그먼트 내의 일부분이 다른 클래스로 인식된 흔적이 있다. 또한 학습에 모든 데이터를 조건 없이 선택하는 경우 (Case-1)에는 학습이 정확하게 이루어지지 않은 것을 알 수 있다(그림 2(b)). 그림 2(c)와 그림 2(d)은 제안한 다중단계 학습에 의하여 학습단계를 3 단계(Stage)로 구분하고 각 단계마다 RGB 값의 범위로 선별한 입력데이터를 선택하여 학습시킨 결과이다. Case-2 형태의 학습진행에서는 동일한 세그먼트에서 일부 학습이 불안정하게 이루어 진 것을 볼 수 있다(그림

2(c)). Case-3 형태의 학습진행이 다른 형태의 학습진행에 비하여 좋은 결과를 나타내고 있다(그림 2(d)). 표 2에 SOM 및 제안한 제안한 학습알고리즘 결과 클러스터들의 위치(RGB)를 나타낸다.



(그림 1) 실험에 사용한 항공영상(282x319)

<표 1> 학습선택유형과 단계별 학습데이터 선택범위 예

학습 선택 유형	학습진행 단계에 따른 선택 데이터의 (R, G, B 값) 범위		
	1 단계 (진행율: 0~39%)	2 단계 (진행율: 40~59%)	3 단계 (진행율: 60~100%)
Case-1	A11		
Case-2	A11	$R, G, B \geq 255 * 0.5$ $R, G, B < 255 * 0.5$	$R, G, B \geq 255 * 0.6$ $R, G, B \leq 255 * 0.4$
Case-3	A11	$R, G, B \geq 255 * 0.7$ $R, G, B \leq 255 * 0.3$	$R, G, B \geq 255 * 0.9$ $R, G, B \leq 255 * 0.1$



(a)



(그림 2) 3 단계 학습에 의한 모듈러 SNN의 출력 영상  
예((a)SOM (b) Case-1, (c) Case-2, (d) Case-3))

<표 2> 3 단계 학습에 의한 모듈러 SNN의 출력 클러스터  
예 ((a)SOM, (b) Case-1, (c) Case-2, (d) Case-3))

clusterID	RGB value
1	(180.00 168.00 154.008)
2	(159.00 144.00 128.00)
3	(138.00 120.00 104.00)
4	(102.00 96.00 79.00)
5	(80.00 83.00 66.00)

(a)

clusterID	RGB value
1	(NaN NaN NaN)
2	(111.97 105.13 86.84)
3	(165.93 155.71 139.48)
4	(67.71 60.80 48.10)
5	(221.02 214.39 205.06)

(b)

clusterID	RGB value
1	(172.71 164.80 149.35)
2	(108.31 104.18 86.61)
3	(228.21 224.43 218.10)
4	(158.94 131.12 112.71)
5	(71.45 72.00 55.77)

(c)

clusterID	RGB value
1	(157.22 125.41 106.98)
2	(227.43 223.44 216.75)
3	(98.51 100.09 81.86)
4	(170.43 161.54 145.70)
5	(67.43 60.65 48.04)

(d)

#### 4. 결론

본 논문에서는 쿨롱 에너지 포텐셜 기반의 모듈러 SNN에서 적용할 수 있는 다중단계 학습알고리즘을 제안하였다. 또한 제안한 다중단계 학습알고리즘을 항공영상 클러스터링 문제에 적용(단계수=3)하여 기존 SOM의 결과와 비교하여 우수함을 보였다. 제안한 학습알고리즘에서는 입력 데이터의 적절한 구분에 의하여 학습이 단계적으로 진행됨으로써 비교적 우수한 학습결과를 확인할 수 있었다. 그러나 제안한 알고리즘을 다른 응용에 적용하기 위해서는 해당 응용에 맞는 적절한 단계의 구분과 그에 따른 학습데이터의 선정에 관련된 연구가 필요할 것이다. 특히 SpikeProp 형태의 학습알고리즘에 효과적으로 적용하기 위해서는 단계적으로 적절한 입력데이터의 선정방안 등 추가적인 연구도 필요하다.

### 참고문헌

- [1] W.Maass, “Networks of spiking neurons: The third generation of neural network models,” Neural Networks, 10, 1659-1671, 1997.
- [2] Y. Yim and S. Oh, “Modeling of vehicle dynamics from real vehicle measurements using a neural network with two-stage hybrid learning for accurate long-term prediction,” IEEE Transactions on VT, 53:1076–1084, 2004.
- [3] B. Meftah, O. Lezoray, and A. Benyettou, “Segmentation and Edge Detection Based on Spiking Neural Network Model,” Neural Processing Letters, vol. 32, 2, 131-146, 2010.
- [4] S. Bothe, J. Kok, and H. Poutre, “Error-Backpropagation in Temporally Encoded Networks of Spiking Neurons,” Neurocomputing, 48(1), 17-37, 2002.
- [5] K. Lee and H. Shi, "A Modular Approach to Construction of Spiking Neural Networks," 2019 International Joint Conference on Neural Networks (IJCNN), Budapest, Hungary, 2019, pp. 1-8, doi: 10.1109/IJCNN.2019.8851740.
- [6] G. Cao, Z. Mao, X. Yang, and D. Xia, “Optical aerial image partitioning using level sets based on modified Chan-Vese model,” Pattern Recognition Letters, vol. 29, no. 4, pp. 457–464, 2008.
- [7] T. Kohonen, “Self-organized formation of topologically correct feature maps”, Biol. Cybern. , 43, 59-69, 1982.