The Journal of the Convergence on Culture Technology (JCCT)
Vol. 6, No. 3, pp.463-468, August 31, 2020. pISSN 2384-0358, eISSN 2384-0366

http://dx.doi.org/10.17703/JCCT.2020.6.3.463
JCCT 2020-8-58

Spiking Neural Networks(SNN) 구조에서 뉴런의 개수와 학습량에 따른 학습 성능 변화 분석

An analysis of learning performance changes in spiking neural networks(SNN)

김용주*, 김태호**

Yongjoo Kim*, Taeho Kim**

요 약 인공지능 연구는 다양한 분야에 적용되며 발전하고 있다. 본 논문에서는 차세대 인공지능 연구 분야인 SNN(Spiking Neural Networks) 형태의 인공지능 구현 방식을 사용하여 신경망을 구축하고, 그 신경망에서 뉴런의 개수가 신경망의 성능에 어떠한 영향을 미치는지를 분석한다. 또한 신경망 학습량을 증가시키면서 신경망의 성능이 어떻게 바뀌는지를 분석한다. 해당 연구 결과를 통해 각 분야에서 사용되는 SNN 기반의 신경망을 최적화 할 수 있을 것이다.

주요어 : 인공지능, 두뇌모사, 신경망, 뉴런, 기계학습

Abstract Artificial intelligence researches are being applied and developed in various fields. In this paper, we build a neural network by using the method of implementing artificial intelligence in the form of spiking natural networks (SNN), the next-generation of artificial intelligence research, and analyze how the number of neurons in that neural networks affect the performance of the neural networks. We also analyze how the performance of neural networks changes while increasing the amount of neural network learning. The findings will help optimize SNN-based neural networks used in each field.

Key words : AI, Neuromorphic, Neural networks, Neuron, Machine learning

Ⅰ. 서 론

최근 10년간 인공지능은 비약적인 발전을 이루었다. 단순히 인공지능 분야에서만 사용되는 것이 아닌, 다양한 분야에 적용되며 인공지능 기술을 전반에 사용하고 있다. 단순 사물인식, 음성인식의 분야를 넘어 자동차, 금융, 스포츠, 예술 등 전반적인 산업 분야에서 인공지능이 적용되어 응용의 폭을 넓히고 있다. 인공지능은 1950년대부터 본격적으로 연구되었다. 1950년대부터 1970년대에 한차례 인공지능 붐이 일어났고 이때 많은 연구가 진행되었고 많은 인공지능 이론을 정립하였다. 하지만 그 당시의 컴퓨팅 기반 기술(컴퓨팅 파워, 통신 네트워크, 스토리지 등)은 현재와는 많은 차이가 있었고, 그 당시의 기술로는 많은 컴퓨팅 자원이 필요한 인

*정회원, 한국전자통신연구원 인공지능연구소 선임연구원 (교신저자)
**정회원, 한국전자통신연구원 인공지능연구소 책임연구원
접수일: 2020년 04월 18일, 수정완료일: 2020년 07월 10일
게재확정일: 2020년 08월 15일
Received: April 18, 2020/ Revised: July 10, 2020
Accepted: August 15, 2020
*Corresponding Author: y.kim@etri.re.kr
Artificial Intelligence Research Laboratory, Electronics and Telecommunications Research Institute (ETRI)

공지능 이론을 현실화할 수 없었기에 일부 제한적인 인공지능만을 구축할 수 있었다.

인공지능의 폭발적인 발전은 딥러닝 방식의 인공지능 기술이 발견되면서 시작되었다고 할 수 있다. 토론토 대학의 제프리 힌튼 교수는 2006년에 제안한 새로운 방식의 인공지능 구현인 딥러닝[1][2] 기법을 발표하였다. 그리고 딥러닝을 적용한 사물인식 알고리즘[3]을 발표하여 기존의 사물인식 알고리즘이 보이던 정확도를 아득히 뛰어넘는 성능을 보이면서 전 세계에 인공지능 붐을 촉발하였다. 그리고 현재에는 산업 전반에서 딥러닝 기반 인공지능을 적용 및 융합 기술[4]을 개발하여 기존에는 처리하지 못했던 문제를 해결하고 있다.

딥러닝의 발전은 컴퓨팅 기반 기술이 발달하여 기존에는 없었던 다양한 기술들이 발전하면서 가능 해졌다. 그중 인공지능의 발전에 도움이 된 부분은 크게 2가지를 꼽을 수 있는데 첫번째는 통신 네트워크, 저장장치 등의 발달로 인해 대량의 데이터 확보가 가능해진 점이다. 딥러닝을 통한 기계 학습을 위해서는 많은 양의 데이터가 필요한데, 기존에 네트워크가 발달하기 전에는 서로 데이터를 공유하기가 어려워 대량의 데이터 확보가 어려웠으나 현재는 인터넷과 다양한 플랫폼을 통해 대량의 데이터에 쉽게 접근할 수 있다. 두번째는 CPU, GPU등의 컴퓨팅 아키텍처의 발전으로 대량의 계산을 효율적으로 빠르게 처리하는 것이 가능해진 점이다. 딥러닝은 학습과정이나 추론과정에서 단순하지만 많은 양의 병렬적 연산이 요구되는데 2000년대 들어 발전한 GPU 등의 병렬 컴퓨팅 아키텍처 기술을 통해 해당 연산을 효율적으로 처리할 수 있게 되었다.

하지만 위와 같은 발전한 기반 기술을 사용하기 어려운 환경도 있다. 임베디드 컴퓨팅 (embedded computing)이나 모바일 컴퓨팅 (mobile computing), 엣지 컴퓨팅 (edge computing) 환경에서는 한정된 컴퓨팅 자원과 제한된 전력 공급 문제로 인해 대량의 계산 자원을 확보하기 힘들고, 제한된 저장공간 및 사용 환경의 문제로 딥러닝 학습에 필요한 충분한 데이터를 공급받기 힘들다. 이러한 환경에서 딥러닝 기술을 사용하기 위해 가지치기(pruning), 모델 양자화(quantization) 등의 경량 딥러닝 기술 등이 제안되고 있으나 계산량을 획기적으로 줄이기에는 근본적인 한계가 있다.

이러한 환경에서 인공지능을 구현하기 위해 최근에는 두뇌의 생물학적 동작 구조를 모방한 SNN(Spiking Neural Networks) 방식의 뉴로모픽 컴퓨팅 (Neuromorphic Computing) 기술이 조명을 받고 있다. SNN 방식의 뉴로모픽 컴퓨팅 기술은 두뇌에서 실제로 정보가 전달되고 가공되는 과정을 모사하여, 뇌를 구성하는 뉴런(neuron)과 시냅스(synapse)로 이루어진 신경망 구성 방식으로 인공지능을 구현하는 방식이다. 두뇌는 입력이 들어온 뉴런만 동작하기 때문에 모든 신경망에서 연산을 동시에 수행하는 기존의 인공 신경망에 비해 저전력의 수행이 가능하다. 실제 인간의 뇌는 1.3~1.4kg의 무게로 다양한 고차원적인 지능을 보이면서도 단지 20W정도의 에너지만을 소비한다.

본 논문에서는 손글씨를 인식하는 SNN 형태의 신경망을 구축하고, 해당 신경망을 구성하는 뉴런의 개수와 학습량의 차이가 성능(글씨 인식률)에 어떠한 영향을 미치는 지를 분석하였다.

II. 뉴런과 시냅스 모델

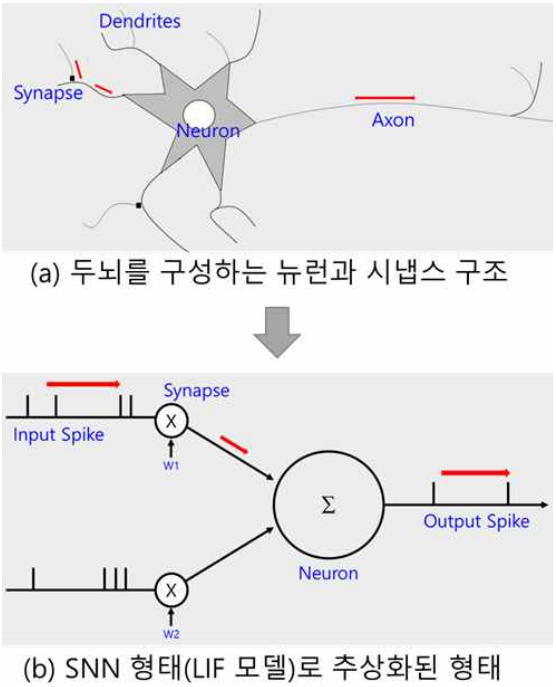

그림 1. 실제 두뇌의 뉴런과 시냅스 구조(a)와 인공지능 구현을 위해 추상화한 모델(b)

Figure 1. (a) the structure of neuron and synapses in a brain, (b) the abstracted model of neuron and synapses

뇌는 그림1 의 (a)와 같은 형태의 뉴런과 시냅스로 이루어져 있다. 인간의 뇌는 뉴런 약 10^{11}개가 연결되어 거대한 네트워크를 구성하고 있는 구조이다. 뉴런은 입력을 받는 통로 역할을 하는 수상돌기(dendrite)와 출력을 보내는 통로 역할을 하는 축삭돌기(axon)를 통해서 신호를 주고받으며 동작한다. 그림1의 (b)는 두뇌의 동작 구조를 모사하여 만든 LIF(Leaky Integrated-and-Fire) 모델[5]이라는 SNN 구현 모델을 보여준다. 입력으로 들어오는 스파이크는 각 시냅스의 가중치를 곱하여 뉴런에서 합쳐지게 되고, 뉴런에서 합쳐진 막전위 (membrane potential) 값이 문턱전압 (threshold voltage)를 넘게 되면 출력 스파이크를 다른 뉴런으로 보내고 뉴런내부의 막전위는 초기화 된다. 해당 모델을 수식화 하여 본 논문에서 사용한 식은 다음과 같다.

$$\tau\frac{dv}{dt} = (v_{rest} - v) + g_e(E_{exc} - v) + g_i(E_{inh} - v) \qquad (1)$$

τ 는 시간상수, v_{rest}는 휴지기의 막전위, g_e와 g_i는 각각 흥분성, 억제성 시냅스의 전도도, E_{exc}와 E_{inh}는 각각 평형상태의 흥분성, 억제성 시냅스의 전위를 나타낸다.

III. Spike-Timing-Dependent Plasticity

SNN에서는 주로 STDP (Spike-Timing-Dependent Plasticity) [6] 학습법이 많이 사용된다. STDP는 시냅스를 사이에 두고 신호를 보내는 쪽인 시냅스전뉴런(presynaptic neuron)과 신호를 받는 쪽인 시냅스후뉴런(postsynaptic neuron) 사이의 스파이크 발생 시간 상관관계를 이용하여 스냅스가중치를 조절한다.

$$\Delta w_{ij} = \sum_{pre}\sum_{post} W(w_{ij}, \Delta t) \qquad (2)$$

식 2는 STDP 개념을 표현한 식으로 Δt는 시냅스후뉴런과 시냅스전뉴런 사이의 스파이크 발생 시간차이를 나타낸다. Δt가 양수이면 시냅스전뉴런이 먼저 발화하고 시냅스후뉴런이 발화한 것이므로 해당 뉴런은 관련이 있다고 볼 수 있다. 그리고 양수인 Δt 값이 작을수록 두 뉴런은 밀접한 관계이므로 시냅스 가중치를 크게 조절해준다. 반대로 Δt 값이 음수이고 그 절대값이 작을수록 두 뉴런은 관련이 없는 것으로 시냅스 가중치를 작게 조절해 준다.

IV. 신경망 구조

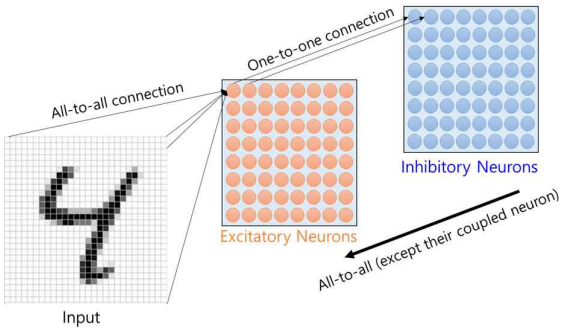

그림 2. 실험에서 사용한 신경망 구조
Figure 2. The neural networks structure used in this paper

본 논문에서 사용한 신경망은 그림2와 같이 2개의 층으로 이루어진 신경망을 사용하였다. 그림2에 나타난 첫번째 층은 입력을 표현한 것으로, 입력 값은 이미지를 L x L 형태로 잘게 나누어서 각 위치의 픽셀 (pixel) 값의 크기를 M x M의 흥분성 뉴런 층으로 전달된다. 각각의 입력 값들은 all-to-all 연결 형태로 Input의 모든 픽셀 값이 각 뉴런에 전부 연결된다. 입력에서 들어오는 값은 일련의 Poisson 분포를 따르는 스파이크 형태로 뉴런으로 전달된다. 억제성 뉴런층은 흥분성 뉴런층과 같은 M x M의 사이즈의 억제성 뉴런으로 구성되어 있다. 흥분성 뉴런층은 억제성 뉴런층에 one-to-one 연결 형태로 흥분성 뉴런에서 각각의 같은 위치에 있는 억제성 뉴런에 연결되어 있다. 억제성 뉴런은 흥분성 뉴런에 all-to-all 형태에서 본인과 같은 위치에 있는 흥분성 뉴런을 제외한 모든 흥분성 뉴런으로 연결되어 있다. 이는 측면억제(lateral inhibition)를 적용하기 위함이다. 이와 같은 형태의 신경망 구조는 숫자인식 신경망 연구에서 많이 사용되고 있다. [7-9]

V. 실험

1. 실험환경

신경망을 구성하는 뉴런의 개수와 학습량이 숫자 인식 정확도에 미치는 영향을 알아보기 위하여 뉴런의 개수와 학습량을 바꿔가며 학습 및 테스트를 진행하였다. 입력에 사용한 데이터는 0-9의 숫자가 28x28 픽셀의 형태로 표현되는 MNIST 데이터셋[10]을 사용하였다. 학습을 위해 60000개의 숫자 데이터를, 학습된 신경망 검증을 위한 정확도 테스트에는 10000개의 숫자 데이터를 사용하였다. 학습은 60000개의 데이터를 1,3,5,7,9회에 걸쳐서 학습 반복 횟수를 다르게 하여 학습을 시킨 뒤 결과를 비교하였다. 사용한 신경망은 4장에서 설명한 것과 같이 N x N 크기의 흥분성 뉴런층과 N x N 크기의 억제성 뉴런층을 가지는 2층의 신경망 구조를 사용하였다. N 값은 10, 15, 20으로 바꿔가며 100개, 225개, 400개의 뉴런을 가지는 신경망층을 구성하고 결과를 비교하였다.

한 개의 데이터당 350ms동안 Poisson 분포에 따라 데이터를 입력하여 학습을 진행하였으며, 다음 데이터를 학습하기 전에 150ms동안 휴식시간을 가지도록 하였다. 학습에 사용한 파라미터는 흥분성 뉴런과 억제성 뉴런의 휴지기 전압을 각각 -65mV, -60mv, 초기화 전압을 각각 -65mv, -45mv, 문턱전압을 각각 -52mv, -40mv, 불응기 간격을 각각 5ms, 2ms로 설정하였다. 시냅스 가중치의 초기값은 무작위 값을 할당하여 실험을 진행하였다. 시뮬레이터는 BRIAN 시뮬레이터[11]를 사용하였다.

2. 실험결과

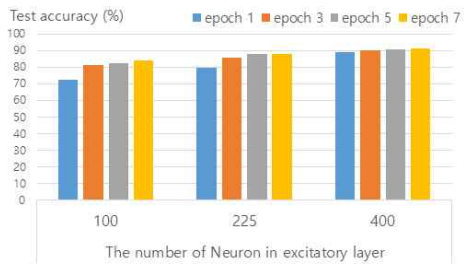

그림 3. 학습에 사용된 뉴런의 개수와 학습횟수 증가에 따른 정확도 증가
Figure 3. A recognition accuracy increases depending on increase of the number of neurons in neural networks and the amount of learning

MNIST 데이터 60000개를 사용한 학습을 한번의 학습이라고 할 때, 학습을 1회, 3회, 5회, 7회씩 학습횟수를 바꿔가며 신경망 학습을 진행하였다. 또한 이 실험을 신경망의 크기(흥분성, 억제성 뉴런층의 개수)를 바꾸어 가며 반복하였다. 그림3은 각 학습결과를 사용하여 숫자 인식을 시도하였을 때 인식률을 나타낸다.

100개의 뉴런으로 구성된 신경망층(ex. 흥분성뉴런 100개 + 억제성뉴런 100개)을 사용한 실험에서는 1회 학습때에는 72.58%의 정확도를 보였다. 하지만 데이터를 반복해서 학습하자 인식률이 점차 올라갔으며 7회 학습을 하였을 때에는 83.84%까지 정확도가 올라가 학습을 많이 할수록 정확도가 좋아지는 결과를 보였다. 하지만 정확도 향상은 선형적으로 증가하지는 않았다. 학습반복을 1회에서 3회로 늘렸을 때에는 72.58%에서 81.41%로 8.83%의 정확도 향상을 보였지만 5회에서 7회로 늘릴 때에는 82.63%에서 83.84%로 1.21%의 향상을 보였다. 사용하는 뉴런의 개수를 늘렸을 때에도 정확도의 향상을 보였다. 7회 학습을 기준으로 뉴런 100개 신경망을 사용하였을 때의 정확도는 83.84% 였으나 400개 뉴런 신경망의 경우에는 91.43%의 정확도를 보여 사용되는 뉴런이 증가할수록 높은 정확도를 보였다.

표1은 뉴런개수와 학습량에 따른 정확도를 보여준다.

표 1. 뉴런개수와 학습량 증가에 따른 정확도 증가
Table 1. A recognition accuracy increases depending on increase of the number of neurons and the amount of learning

Epoch	The number of neurons in an excitatory, an inhibitory layer		
	100	225	400
1	72.58%	79.38%	89.15%
3	81.41%	85.65%	90.05%
5	82.63%	87.88%	90.51%
7	83.84%	88.07%	91.43%

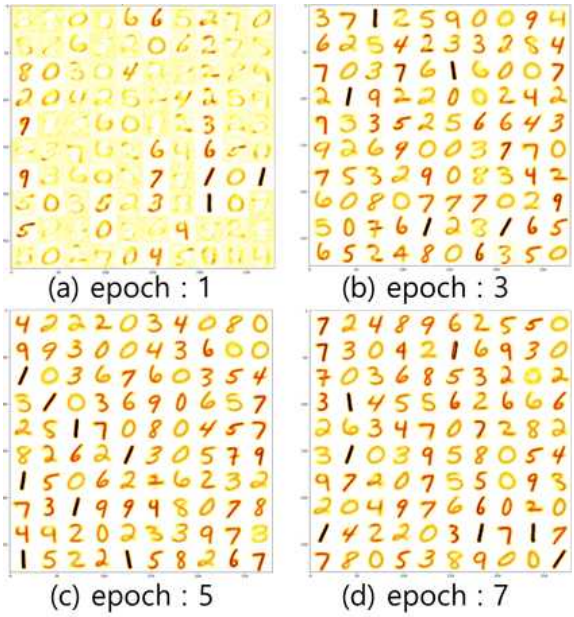

그림 4. 입력층과 흥분성 뉴런층 사이를 연결하는 시냅스의 가중치를 표현한 그림. 학습 횟수에 따라 가중치가 선명해지는 것을 확인할 수 있다.

Figure 1. The weights of synapses between excitatory neuron layer and inhibitory neuron layer

그림4는 뉴런 100개 신경망을 사용하였을 때 입력에서 흥분성 뉴런층으로 연결된 시냅스 연결의 가중치를 색으로 표현한 그림이다. 가중치가 0일때는 흰색부터 가중치가 높아질수록 노란색->빨간색->검은색으로 가중치가 클수록 색상을 진하게 표현하였다. 학습횟수 1회일 때에는 시냅스 가중치들이 한창 학습 중으로, 아직 모든 입력에 골고루 반응하는 형태를 띄지 않고 있다. 학습횟수를 늘릴수록 각각의 뉴런으로 향하는 가중치들이 점점 특정 입력에 잘 반응하도록 학습이 되어 학습횟수 7회에는 가중치가 각 뉴런이 반응하는 숫자에 최적화되어 반응하도록 학습된 결과를 볼 수 있다.

VI. 결 론

본 논문에서는 숫자를 인식하는 SNN 형태의 신경망을 구축하고, 해당 신경망을 구성하는 뉴런의 개수와 학습량을 변화시키면서 성능(글씨 인식률)에 어떠한 변화가 있는지를 분석하였다. 학습량을 증가시키면 신경망의 정확도가 증가하는 것을 확인할 수 있었고, 그 정확도 향상은 학습량 증가에 선형적으로 비례하지는 않고 점점 정확도 향상이 줄어드는 것을 확인하였다. 또한 신경망을 구축하는데 사용한 뉴런의 개수를 늘리면 정확도가 증가하는 것을 확인하였다.

본 연구를 통해서 뉴런의 개수와 학습량의 증가에 따라 정확도가 증가하는 것을 확인하였다. 앞으로 신경망을 적용할 환경에 따라 필요한 정확도에 맞추어 사용되는 뉴런의 개수를 늘리고 또 충분한 학습을 진행하여 최적화된 개수의 뉴런을 사용할 수 있기를 기대한다.

References

[1] Hinton, Geoffrey E. "Learning multiple layers of representation". Trends in Cognitive Sciences. 11 (10): 428 - 434

[2] Hinton, G. E. et al. "A Fast Learning Algorithm for Deep Belief Nets" Neural Computation. 18 (7): 1527 - 1554

[3] Alex Krizhevsky et al. “ImageNet Classification with Deep Convolutional Neural Networks” Communications of the ACM Vol. 60, No. 6

[4] Jaebok Park, Seungmok Yoo, Seokjin Yoon, Kyunghee Lee, Changsik Cho, “Interworking technology of neural network and data among deep learning frameworks” ETRI Journal Volume 41, Issue 6

[5] Abbott, L.F. "Lapique's introduction of the integrate-and-fire model neuron (1907)" Brain Research Bulletin. 50 (5/6): 303 - 304

[6] Bi, G. and Poo, M., “Synaptic Modifications in Cultured Hippocampal Neurons: Dependence on Spike Timing, Synaptic Strength, and Postsynaptic Cell Type,” Journal of Neuroscience, vol. 18, no. 24, pp. 10464 - 10472, 1998.

[7] P. U. Diehl, M. Cook, “Unsupervised learning of digit recognition using spike-timing-dependent plasticity,” Frontiers in Computational Neuroscience, Aug. 2015.

[8] Hazan H., Saunders D., Sanghavi D., Siegelmann H., and Kozma, R., “Unsupervised learning with self-organizing spiking neural networks,” in 2018 International Joint Conference on Neural Networks (IJCNN), Rio de Janeiro, Brazil, Jul. 2018

[9] Matthias Oster and Shih-Chii Liu. 2006. Spiking inputs to a winner-take-all network. In Advances in Neural Information Processing Systems (NIPS). 1051 - 1058, 2004.

[10] Y. LeCun, L. Bottou, Y. Bengio, and P., Haffner,

"Gradient-based learning applied to document recognition." Proceedings of the IEEE, vol. 86, no. 11, pp. 2278 - 2324, Nov. 1998.
[11] D. F. M. Goodman, R. Brette, "The Brian simulator," Frontiers in Computational Neuroscience, Sep. 2009.
[12] Jee-Young Lee, "Deep Learning Research Trend Analysis using Text Mining" IJACT Vol.7 No.4
[13] Ju-eun Kim., "An Analysis of the effect of Artificial Intelligence on Human Society" JCCT Vol.5 No.2

※ 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2018-0-00769, 인공지능 시스템을 위한 뉴로모픽 컴퓨팅 SW 플랫폼 기술 개발)