Fashion-MNIST 환경에서의 Sensory Adaptation 기반 Spiking Neural Network의 안정성 분석

박재연, 이정원*
중앙대학교 전자전기공학부, 서울대 차세대반도체 혁신융합대학사업단*
e-mail : heenseo2@cau.ac.kr, jugnwon0736@snu.ac.kr*

Stability Analysis of a Sensory Adaptation-Based Spiking Neural Network in the Fashion-MNIST Environment

Jaeyeon Park, Jungwon Lee*
Chung-Ang University, Seoul National University*

Abstract

Sensory Adaptation (SA) has been proposed in prior work as an alternative to Spike-Frequency Adaptation (SFA) in Spiking Neural Network (SNN) to achieve biologically plausible and energy-efficient learning. While prior studies validated SA under the MNIST dataset, its stability under more complex visual environments has not been fully investigated. In this work, we analyze the behavior of SA in a Fashion-MNIST dataset, which exhibits higher intra-class variation and visual complexity. A CuPy and JIT-optimized SNN simulator was implemented to enable large-scale experiments up to 60,000 training iterations. Through systematic parameter sweeps, we reveal that SA exhibits collapse-prone dynamics under increased input complexity and derive a stable operating region that prevents sensitivity collapse. Experimental results show that SA achieves 61.44% accuracy, compared with 66.49% for SFA, while reducing average spike count and the number of activated neurons. These findings demonstrate the trade-off between classification performance and spike efficiency and provide practical guidelines for stable SA operation in complex datasets.

I. 서론

스파이킹 신경망(Spiking Neural Network, SNN)은 이벤트 기반 계산 구조를 통해 높은 에너지 효율을 제공하는 모델로, 뉴로모픽 하드웨어 구현에 적합한 대안적 인공신경망 구조로 주목받고 있다. 특히 Diehl과 Cook [1]은 MNIST 손글씨 숫자 인식을 위해 STDP 기반 2-layer SNN 구조를 제안하였으며 해당 구조는 LIF 뉴런, lateral inhibition 기반 Winner-Take-All(WTA) 경쟁, Spike-Frequency Adaptation (SFA)을 결합한 대표적인 비지도 학습 모델이다.

SFA는 발화 이후 임계전압을 증가시켜 뉴런의 과도한 활성화를 억제하는 방식으로 구현된다. 그러나 입력 복잡도가 증가하는 경우 임계전압 상승이 누적되어 일부 뉴런이 장기간 발화하지 않는 dead neuron 현상이 발생할 수 있다. 이러한 한계를 개선하기 위해 기존 연구에서는 입력 민감도를 조절하는 Sensory Adaptation(SA) 기법이 제안되었다[2]. SA는 임계전압을 변화시키는 대신, 흥분성 입력 전도도를 동적으로 감소시켜 생물학적 감각 적응 메커니즘을 모사한다. 기존 연구는 MNIST 환경에서 SA의 안정성과 낮은 스파이크 소모 특성을 보고하였다. 그러나 MNIST는 구조적 복잡도가 낮고 intra-class variation이 제한적이므로 복잡한 시각 데이터 환경에서 SA의 동작 특성은 충분히 검증되지 않았다. Fashion-MNIST는 동일한 해상도를 유지하면서도 텍스처 및 형태 다양성이 높아 입력 스파이크 분포가

불균형하게 형성될 가능성이 크다[7]. 이러한 환경에서는 민감도 붕괴(sensitivity collapse)가 발생할 수 있으며 SA의 안정성에 대한 추가 분석이 필요하다. 본 연구에서는 Fashion-MNIST 환경에서 SA와 기존 SFA 구조를 동일 조건 하에 비교하고 SA의 민감도 감소-회복 동역학이 데이터 복잡도에 따라 비선형적으로 반응함을 분석하고 그 안정 조건이 특정 파라미터 영역에 국한됨을 규명한다.

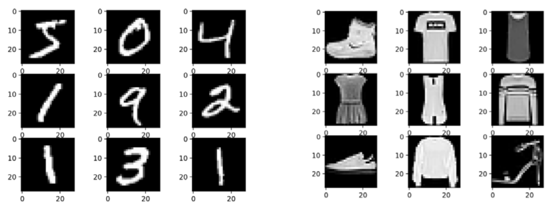

그림 1. MNIST(좌측)와 Fashion-MNIST(우측)의 시각적 구조 비교

II. 본론

2.1 네트워크 구조

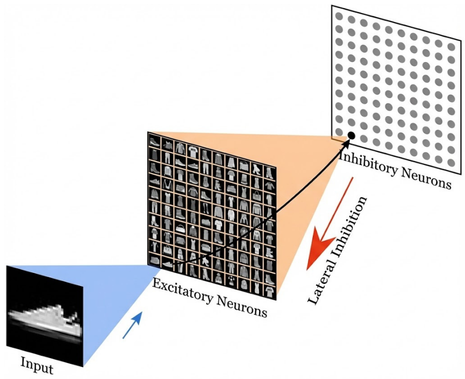

그림 2. STDP 기반 2-layer SNN 구조

본 연구에서 사용한 스파이킹 신경망은 784-625-625 구조의 3계층 Winner-Take-All(WTA) 네트워크이다. 입력층은 28×28 픽셀을 그대로 수용하는 784개의 입력 뉴런으로 구성되며 중간층은 625개의 흥분성 뉴런(Sensory layer), 마지막은 625개의 억제성 뉴런으로 구성된다. 흥분성 뉴런과 억제성 뉴런은 1:1로 연결되어 lateral inhibition을 형성한다. 입력 이미지는 Poisson spike encoding을 통해 시간 영역 스파이크 열로 변환하였다. 각 이미지는 350ms 동안 제시되며 픽셀 밝기값에 비례하여 발화 확률이 결정된다. 생성된 입력 스파이크는 784×625 시냅스를 통해 흥분성 뉴런으로 전달된다. 흥분성 뉴런의 막전위는 conductance-based LIF(Leaky Integrate-and-Fire) 모델을 따른다 [3].

$$\tau_m \frac{dV}{dt} = -(V - E_{rest}) + g_e(E_{exc} - V) - g_i(E_{\in h} - V) \quad (1)$$

여기서 V 는 막전위, τ_m 은 막전위 시간상수, E_{rest} 는 resting potential, E_{exc}와 E_{inh}는 각각 흥분성 및 억제성 역전위이다. g_e와 g_i는 시간에 따라 변화하는 흥분성 및 억제성 시냅스 전도도이다. 막전위가 임계값 V_{th} 를 초과하면 뉴런은 spike를 발생시키고 V_{reset} 으로 초기화된다.

가중치 학습은 trace 기반 STDP 규칙을 따른다 [4].

$$\Delta w = \eta (x_{pre} - x_{tar})(w_{\max} - w)^{\mu} \quad (2)$$

여기서 w는 시냅스 가중치, η는 학습률, x_{pre} 는 pre synaptic trace, x_{tar} 는 기준 trace 값, $w_{\max}$는 최대 가중치, μ는 가중치 의존성 지수이다. 이 규칙은 입력-출력 스파이크 간 시간 상관관계를 기반으로 가중치를 조절한다.

2.2 Spike-Frequency Adaptation (SFA)

기존 구조에서는 발화 이후 임계전압을 증가시키는 Spike-Frequency Adaptation(SFA)을 사용한다[5].

$$V_{th}^{eff} = V_{th} + \theta$$
$$\tau_\theta \frac{d\theta}{dt} = -\theta \quad (3)$$

여기서 θ는 발화 이력에 따른 추가 임계전압이며, 발화 시 증가하고 시간에 따라 감쇠한다. SFA는 발화 이력에 따라 임계전압을 증가시킴으로써 특정 뉴런의 과도한 활성화를 억제한다. 그러나 입력 복잡도가 증가할 경우 임계전압 상승이 누적되어 일부 뉴런이 장기간 비활성화되는 dead neuron 현상이 발생할 수 있다. 또한 WTA 경쟁이 과도하게 분산되어 스파이크 소모량이 증가하는 경향이 보고되었다.

2.3 Sensory Adaptation (SA) 구조

기존 연구에서는 SFA의 한계를 완화하기 위해 Sensory Adaptation(SA) 기법이 제안되었다. SA는 임계전압을 조절하는 대신, 흥분성 입력의 민감도를 동적으로 감소시키는 방식이다 [6].

SA가 적용된 경우, 막전위 방정식의 흥분성 입력 항은 다음과 같이 수정된다.

$$\tau_m \frac{dV}{dt} = -(V - E_{rest}) + g_{sens} \cdot g_e(E_{exc} - V) - g_i(E_{\in h} - V) \quad (4)$$

여기서 g_{sens}는 입력 민감도 계수이다. 민감도는 발화 시 감소하고, 비발화 시 회복된다.

$$발화\ 시 : g_{sens}(t+1) = \chi g_{sens}(t) \quad (5)$$

$$비발화\ 시 : \tau_{sens}\frac{dg_{sens}}{dt} = g_0 - g_{sens} \quad (6)$$

여기서 χ는 감소 비율, τ_{sens}는 회복 시간상수, g_0는 초기 민감도이다. 이 구조는 반복 발화 시 입력 반응 세기를 점진적으로 감소시켜 스파이크 소비를 억제한다.

2.4 Fashion - MNIST 환경에서의 안정성 분석

MNIST는 구조적 복잡도가 낮고 intra - class variation이 제한적인 반면, Fashion - MNIST는 텍스처 및 형태 다양성이 높아 입력 스파이크 분포가 불균형하게 형성된다. 이러한 환경에서는 일부 뉴런에 스파이크가 집중되며, SA 적용 시 민감도 감소가 빠르게 진행될 수 있다.

발화 횟수 N에 대해 민감도는 다음과 같이 근사적으로 표현된다.

$$g_{sens} \approx g_0 \chi^N \quad (7)$$

$\chi < 1$ 이므로 반복 발화 시 민감도는 지수적으로 감소한다. 감소 항이 회복 항보다 우세한 경우,

$$g_{sens} \rightarrow 0 \quad (8)$$

로 수렴하며 이를 sensitivity collapse라 정의한다. 본 연구에서는 χ, τ_{sens}, 억제 강도 V_I에 대한 파라미터 스윕을 통해 입력 복잡도 증가에 따른 SA의 민감도 붕괴 경향을 정량적으로 분석하고, 붕괴가 발생하지 않는 안정 영역을 도출하였다. 이를 통해 SA가 복잡한 시각 데이터 환경에서도 안정적으로 동작할 수 있는 조건을 규명하였다.

III. 구현

3.1 연산 구조 및 실험 환경

Fashion - MNIST 환경에서는 입력 스파이크 밀도가 증가하여 막전위 갱신, 시냅스 전도도 누적, 억제 전달 연산량이 크게 증가한다. 기존 CPU 기반 구현으로는 장기 학습 및 다중 하이퍼파라미터 탐색 수행이 제한적이었다. 이에 본 연구에서는 연산 유형에 따라 GPU와 CPU를 분리한 하이브리드 구조로 시뮬레이터를 재구성하였다. 막전위 업데이트 및 입력 스파이크 처리와 같은 대규모 벡터 · 행렬 연산은 CuPy 기반 GPU 연산으로 수행하였으며, 조건 분기와 반복 처리가 많은 STDP 가중치 갱신 및 적응 변수 업데이트는 JIT 컴파일 기반 CPU 연산으로 처리하였다. 이를 통해 60,000 iteration 장기 학습 및 다중 파라미터 스윕 실험을 동일 환경에서 안정적으로 수행하였다.

3.2 하이퍼파라미터 탐색

Fashion - MNIST 환경에서 SA를 적용할 경우, 입력 스파이크 집중 현상으로 인해 민감도 감소가 가속화되며 sensitivity collapse가 발생할 수 있다. 초기 설정에서는 약 50,000 iteration 이후 발화가 급격히 감소하는 현상이 관찰되었다. 이에 따라 Fashion - MNIST 환경에서 SA가 형성하는 민감도 감소-회복 동역학의 균형 조건을 분석하였다.

탐색은 두 단계로 수행하였다. 1. 억제 전위 V_I 스윕, 2. V_I 를 고정한 상태에서 감소 계수 χ 및 회복 상수 τ 동시 스윕 평가 지표는 Accuracy, 입력당 평균 발화 뉴런 수(NOI), Single - WTA 비율로 통일하였다.

V_I	Accuracy	NOI	Single - WTA
0.18	44.30%	121.43	57.80%
0.20	44.20%	118.00	58.10%
0.22	44.90%	113.36	59.70%
0.24	**44.50%**	**90.99**	**65.10%**
0.25	42.20%	105.47	67.30%
0.26	42.70%	92.61	68.40%
0.28	42.90%	90.58	69.20%

표 1. 억제 전위 V_I 스윕 결과

낮은 V_I 영역에서는 NOI가 과도하게 증가하여 경쟁 구조가 분산되었고, 높은 V_I 영역에서는 발화 억제가 강해 정확도가 감소하였다. V_I =0.24 에서 NOI가 급격히 감소하면서도 정확도 손실이 크지 않아 이후 실험에서 해당 값을 고정하였다.

χ	τ	Accuracy	NOI	Single - WTA
0.9993	7.7	43.40%	98.05	67.60%
0.9993	**8.1**	**44.70%**	**96.50**	**65.00%**
0.9993	8.5	43.80%	81.38	68.50%
0.9991	7.7	43.80%	90.31	64.00%
0.9991	8.1	42.90%	100.67	63.40%
0.9991	8.5	44.60%	92.73	65.50%
0.9987	7.7	43.40%	88.65	66.70%
0.9987	8.1	43.70%	99.75	65.40%
0.9987	8.5	43.50%	91.28	66.70%

표 2. 감소 계수 χ 및 회복 상수 τ동시 스윕 결과

감소 계수 χ가 작아질수록 민감도 감소 속도가 빨라졌으며, 회복 상수 τ가 증가할수록 회복이 지연되어 collapse 위험이 증가하였다. χ=0.9993,τ=8.1 조합은 정확도 손실이 최소이며, NOI 및 경쟁 지표가 안정적으로 유지되는 영역에 해당하였다. 스윕 결과를 기반으로 정확도, 경쟁 집중도, 발화 효율의 균형이 유지

되는 안정 영역을 선정하였다.

$$V_I = 0.24,\ \chi = 0.9993,\ \tau = 8.1$$

3.3 장기 학습 및 SFA 비교

선정된 파라미터 조합으로 60,000 iteration의 장기 학습을 수행하였다. 해당 설정에서는 민감도 붕괴 없이 전 구간에서 발화가 유지되었으며, 10,000개 테스트 데이터에 대한 최종 성능은 다음과 같다.

	Accuracy	Avg Spikes	NOI	Single-WTA
SA	61.44%	216.77	28.33	77.10%
SFA	66.49%	286.98	50.35	31.10%

표 3. SA와 SFA 비교 결과

SFA는 정확도에서 우위를 보였으나, SA는 평균 스파이크 수를 약 24% 감소시켰으며 활성 뉴런 수(NOI)를 크게 줄였다. 또한 Single-WTA 비율이 77.10%로 증가하여 경쟁 구조가 보다 집중적으로 형성됨을 확인하였다. 구현 코드와 주요 실험 설정은 GitHub 저장소에 공개하였다: https://github.com/jaypark0115/fashion-mnist-sa-snn

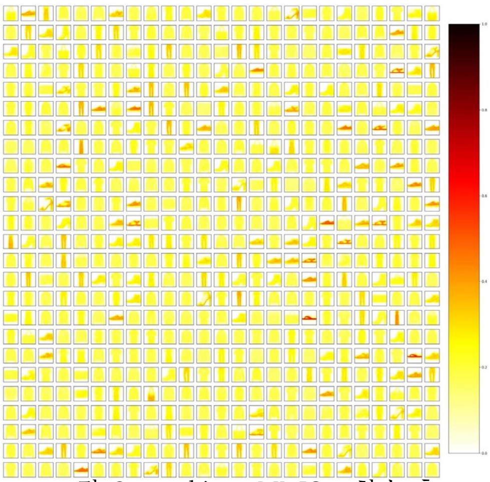

그림 3. Fashion-MNIST 학습 후 625개 뉴런의 입력 weight map

IV. 결론 및 향후 연구 방향

본 연구는 Fashion-MNIST 환경에서 입력 복잡도 증가에 따라 SA가 보이는 민감도 붕괴 특성을 분석하고 안정적인 장기 학습을 위한 파라미터 조건을 실험적으로 규명하였다. 최종 선정된 파라미터 조합 ($V_I = 0.24$, $\chi = 0.9993$, $\tau = 8.1$)에서는 60,000 iteration 장기 학습 동안 민감도 붕괴 없이 안정적인 발화가 유지되었다. 실험 결과, SA는 SFA 대비 분류 정확도는 낮았으나(61.44% vs. 66.49%), 평균 스파이크 수와 활성 뉴런 수를 유의미하게 감소시켰으며, Single-WTA 비율을 크게 향상시켰다.

다만 정확도 측면에서는 여전히 SFA 대비 열세를 보였으며, 이는 입력 복잡도가 높은 환경에서 민감도 감소가 특징 추출 다양성을 제한했기 때문으로 해석된다. 향후 연구에서는 다음과 같은 개선 방향을 고려할 수 있다. 고정된 감소 계수 대신 동적 적응률 조절 기법을 도입하여 초기 학습 단계와 수렴 단계에서 서로 다른 적응 강도를 적용하는 방법이 필요하다. 또한 단일 계층 WTA 구조에서 벗어나 다계층 구조로 확장하여 입력 복잡도에 대한 표현력을 강화하는 것이 필요하다. 이러한 결과는 SA가 복잡한 입력 환경에서 안정적으로 동작하기 위해서는 정확도와 스파이크 효율 사이의 균형을 고려한 파라미터 설정이 필요함을 보여준다.

Acknowledge

본 과제는 교육부와 한국연구재단의 재원으로 자원을 받아 수행된 첨단분야 혁신 융합 대학 사업의 연구 결과입니다.

참고문헌

[1] P. U. Diehl and M. Cook, “Unsupervised learning of digit recognition using spike-timing-dependent plasticity,” Front. Comput. Neurosci., vol. 9, Art. no. 99, pp. 1–17, Aug. 2015.

[2] M. Jeon, “A study on the low-power operation of the spiking neural network using the sensory adaptation method,” Master’s thesis, Dept. of Electronic and Electrical Engineering, Chung-Ang Univ., Seoul, Korea, 2023.

[3] W. Gerstner and W. M. Kistler, Spiking Neuron Models: Single Neurons, Populations, Plasticity. Cambridge, U.K.:Cambridge Univ. Press, 2002.

[4] G. Q. Bi and M. M. Poo, “Synaptic modifications in cultured hippocampal neurons: dependence on spike timing,” J. Neurosci., vol. 18, no. 24, pp. 10464–10472, 1998.

[5] J. Benda and A. V. Herz, “A universal model for spike-frequency adaptation,” Neural Comput., vol. 15, no. 11, pp. 2523–2564, 2003.

[6] B. Wark, B. N. Lundstrom, and A. Fairhall, “Sensory adaptation,” Curr. Opin. Neurobiol., vol. 17, no. 4, pp. 423–429, 2007.

[7] H. Xiao, K. Rasul, and R. Vollgraf, “Fashion-MNIST:A novel image dataset for benchmarking machine learning algorithms,” arXiv:1708.07747, 2017.