

스마트 헬스 시티를 위한 ECG 기반 부정맥 감지 SNN 알고리즘

이 충 섭*, 이 원 규*, 한 승 우*, 박 철 수^o

ECG-Based Arrhythmia Detection SNN Algorithm Using STDP and Spike Inference for Smart Health City

Choongseop Lee*, Wongyu Lee*, Seungwoo Han*, Cheolsoo Park^o

요 약

의료 시스템의 변화와 인구 고령화, 작금의 코로나 사태로 인하여 헬스케어 산업에 많은 관심과 투자가 증대되고 있다. 또한 딥 러닝을 필두로 하는 머신러닝 기술의 발전은 다양한 분야에서 두각을 내기 시작했고 그 중 헬스케어 서비스에 대한 적용과 확산이 빠르게 일어나고 있다. 하지만 기존 딥 러닝 모델은 많은 전력이 소모되고 소형화하기 어렵다는 단점이 있어 스마트 시티가 요구하는 웨어러블 디바이스에 적합하지 않다. 이에 저전력과 병렬성을 내재한 차세대 인공지능 연구 분야인 Spiking Neural Network(SNN)이 대안으로 떠오르고 있다. 본 논문에서는 시냅스 전, 후 시간차를 이용하여 학습하는 비지도학습 알고리즘인 STDP를 중심으로 SNN을 설계하였다. 또한 기존 연구들에서 다루지 않았던 ECG 부정맥 데이터 셋을 SNN에 적용하고 누적 스파이크 기반 추론에 따라 정확도와 민감도, 특이도를 비교 분석한다. 실험 결과를 통해 얻은 문제점과 개선점들을 통해 헬스케어 기술로써의 SNN의 가능성을 보이고 새로운 시사점을 보이고자 한다.

키워드 : SNN, STDP, ECG, 부정맥, 스마트 시티

Key Words : spiking neural network, STDP, ECG, arrhythmia, smart city

ABSTRACT

Due to changes in the medical system, an aging population, and the current COVID-19 crisis, a lot of interest and investment in the healthcare industry is increasing. The development of machine learning technology led by deep learning drives its applications to healthcare services. However, the conventional deep learning models consume a lot of power and are difficult to miniaturize, so they are not suitable for wearable devices required by smart cities. Accordingly, interests in spiking neural network (SNN), a next-generation artificial intelligence research field with low power and parallelism, are emerging as an alternative. In this paper, SNN is designed with STDP, an unsupervised learning algorithm that learns time difference between pre and post synapses. It is also applied to ECG arrhythmia data sets and produces accuracy, sensitivity and specificity according to cumulative spike-based inference. With the experiment results, we want to show the possibility of SNN as a healthcare technology and new implications too.

※ “본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 SW중심대학지원사업의 연구결과로 수행되었음“(2017-0-00096)

• First Author : Kwangwoon University Department of Computer Software, cndtjq97@kw.ac.kr, 학생회원

^o Corresponding Author : Kwangwoon University Department of Computer Engineering, parkcheolsoo@kw.ac.kr, 정회원

* Kwangwoon University Department of Intelligent Information System and Embedded Software Engineering, leew1729@gmail.com, 학생(석사), 학생회원; seungwoohan@kw.ac.kr, 학생회원

논문번호 : 202011-277-0-SE, Received November 6, 2020; Revised November 20, 2020; Accepted November 23, 2020

1. 서 론

4차 산업 혁명의 새로운 플랫폼으로 등장한 스마트 시티가 주요한 화두로써 떠오르고 있다. 스마트시티란 빅데이터의 증가와 유비쿼터스 컴퓨팅의 발전에 의해 인간의 신경망처럼 도시 구성구석까지 연결되어, 사용자가 언제 어디서나 컴퓨팅 자원을 이용해 다양한 서비스를 제공받을 수 있는 도시를 일컫는 말이다^[1]. 컴퓨터, 네트워크의 발전이 스마트시티를 견인한 것처럼 현재에도 ICT/Intelligence/ Information 분야에서 가장 많은 연구가 이뤄지고 있다. 2014년 ITU-T의 조사^[2]에 따르면 ICT가 시민들을 위한 보안, 운송 그리고 헬스케어 서비스를 제공할 것으로 전망한다. 또한 환경, 삶의 질, 경제 등을 스마트시티 내 주요한 키워드로 여기고 시민, 정부, 기업의 변화를 예측하였다. 이처럼 스마트시티는 젊고 거대하며 광범위하기에 많은 연구들에서 과제와 개념, 용어 정리에 힘쓰고 있다^[3,4].

반면 인공지능과 딥 러닝은 보다 오래된 연구와 발전의 역사를 가지고 있다. 1956년 다투머스 쾨퍼린스를 통해 AI라는 이름이 생겨난 이래 2차례의 침체기와 황금기를 거치며 주제가 정립되지 못하고 여러 가능성만 제기되어왔다. 이윽고 경사하강법과 오차 역전파 기반의 다층 신경망인 Deep Neural Network (DNN)이 제시되었고^[5,6] 2012년 이미지 분류 분야에서 83.6%의 정확도를 기록하면서^[7] 딥 러닝 모델이 인공지능 분야에서 핵심기술로써 자리매김한다. 이러한 딥 러닝 모델은 방대한 양의 데이터와 연산과정이 필요하다. 2000년대 이후의 웹기반 네트워크의 활성화와 GPU를 필두로한 컴퓨터 아키텍처의 발달로 인해 충분한 데이터와 컴퓨팅 파워가 확보되었고 딥 러닝은 비약적인 발전을 이룩할 수 있었다.

하지만 높은 CPU/GPU 사양이 필요한 딥 러닝의 단점들로 인해 임베디드, 웨어러블 디바이스에 딥 러닝 모델을 적용하기에는 많은 어려움이 생긴다. 또한 실제 포유류 뇌의 신경질은 오브젝트를 판별하는 데 10 ~ 20W 정도의 에너지만 소비하여^[8] DNN 기반의 모델들과 큰 차이를 보인다. 이에 생물학적으로 유사한 알고리즘들과 뉴로모픽 칩들을 연구 중에 있으며 가장 활발히 연구되고 있는 분야가 Spiking Neural Network(SNN)이다^[9]. SNN은 3세대 신경망이라 불리며 보다 생물학적으로 타당한 모델을 구현하는데 목적을 두고 있다. 뉴런과 시냅스 연구를 통해 신경망 구조를 설계하고 데이터가 전달되는 방식, 스파이크를 모방한다. 이러한 스파이크들은 32bit, 혹은 64bit 단위의 데이터를 처리하는 DNN과는 달리 오직 1bit 단

위로 전달되기에 임베디드, 웨어러블 디바이스에 필수적인 저 전력을 보장한다. 또한 상대적으로 느린 연산 속도를 보여주던 CPU/GPU 기반이 아닌 SNN 모델에 최적화된 뉴로모픽 칩^[10]을 활발히 연구 중에 있다.

SNN에서 주요한 연구과제는 생물학적으로 타당하지만 동시에 효과적인 성능을 보장하는 학습방법을 찾는 것이다. 이에 전-후 시냅스 간 스파이크 발화 시간 차이를 통해 학습하는 spike-timing-dependent plasticity (STDP)^[11] 알고리즘이 뇌의 학습방법과 유사하다는 사실을 밝혀내었다. 초기 연구에서는 인공신경망의 오차 역전파 학습 방식을 SNN에 적용하여 실험하였지만 이내 곧 Brader et al. (2007)^[12], Diehl et al. (2015)^[13]과 같은 논문들에서 spike기반의 STDP 학습이 좋은 성능을 보임을 증명하였다.

이 STDP를 통해 스파이킹 신경망에 대하여 뉴로모픽 관점에서 맵리스터 연구^[14]나 spatio- and spectro- temporal data(SSTD)에 적합한 SNN 연구^[15]와 같이 뉴로모픽 칩과 시공간, 주파수 패턴에 대해 활발한 연구가 가능하였다. 하지만 SNN에 대한 대다수의 실험이 하드웨어 기반의 연구로 소프트웨어 관점의 연구는 상대적으로 부족한 실정이다. 효율적인 하드웨어 설계를 위해서 최적화된 소프트웨어 기법이 필요하다는 사실^[16]은 딥 러닝 모델 발전에 의해 널리 알려진 정론이다. 또한 소프트웨어 분야에서 연구가 진행된 앞선 논문들^[12,13]이나 국내 논문들^[17,18] 모두 MNIST 손 글씨 데이터에 대한 실험결과로, 테스트 데이터 셋을 넘어 웨어러블 디바이스와 같은 실용적인 하드웨어에 적용하기에는 아직 연구가 부족한 상황이다. 특히 ECG, PPG, EEG 등의 생체 신호 데이터들은 주파수 분석에 특화된 SNN과 잘 어울리고 헬스케어 서비스에 활용 가치가 높지만 관련된 연구가 전무한 실정이다.

이러한 맥락에서 본 연구는 MIT-BIH Arrhythmia ECG 데이터^[19]를 STDP 알고리즘 기반의 SNN을 통해 학습하여 성능을 소프트웨어 모델에서 평가하고자 한다. 누적된 스파이크를 3가지 방식으로 추론하여 각각의 정확도, 민감도, 특이도를 구하고 이를 비교 분석한다. 도출해낸 결과를 통해 문제점과 개선점을 파악하고, 스마트 시티의 핵심 산업 중 하나인 헬스케어 분야에 새로운 기술로써의 SNN의 가능성을 제안하고자 한다.

2장에서는 스마트시티의 등장 배경과 헬스케어 산업, 차세대 신경망의 필요성을 언급하고 3장에서는 스파이크 기반 네트워크 구조의 발전과정을 서술하고 뉴런 모델, 포아송 인코딩, STDP 중심으로 연구에서

사용된 2-Layer Spikes Network 구조를 설명한다. 4장에서는 실험에 사용할 MIT-BIH Arrhythmia의 데이터 분류와 전처리 과정을 선보인다. 5장에서 실험 환경을 명시하고 결과를 비교분석하여 6장 결론을 통해 마무리한다.

II. Smart City

스마트시티의 등장에는 서론에서 언급한 바와 같이 정보화 기술 발전에 따른 향상된 서비스 제공 목적이 배경이 되지만 또 다른 측면에서는, 여러 연유로 증가한 도시문제를 해결하기 위해 스마트시티가 필요성이 대두된다. UN DESA의 2018 ‘유엔 세계 도시화 전망’ 보고서^[20]에 따르면 세계 인구의 55%인 42억 명이 도시 지역에 살고 있다고 말한다. 이러한 도시인구는 2050년 68억 명으로 늘어날 것으로 예상하며 1950년 7억 5천만 명에 비하면 100년 사이 도시인구만 9배 가까이 증가할 것으로 예측한 것이다. 도시인구의 증가는 저소득 및 중하위 소득 국가들에서 더욱 두드러지는데, 개발도상국 내 급진적인 도시인구 증가는 각종 도시문제의 원인이 된다. 증가한 쓰레기와 산업 재해로 인해 대기, 수질이 오염되어 한해 100만 건 이상의 천식, 발작이 보고되기도 한다. 하지만 많은 시민들이 적절한 치료를 받지 못하고 있는 상황이다^[21].

이와 상반되게, DESA의 보고서에 따르면 부산과 나가사키 같은 한국, 일본의 몇몇 대도시에서는 오히려 지속적으로 인구가 감소 추세를 보였는데, 이것의 주된 원인이 저출산이라 지적한다. 이 저출산이 고령화와 맞물리며 또 다른 양상의 도시문제를 유발한다. UN의 산하기구 UNFPA의 ‘21세기의 고령화: 축복받을 성과와 당면한 도전’ 보고서^[22]에 따르면 2050년 전 세계 인구의 5분의 1이 60세 이상의 노년층에 속할 것이라 예측한다. 인구고령화가 나라의 발전을 의미한다고 평가하는 동시에 고령자들을 위한 보건의료 서비스 마련은 엄청난 난제라고 평한다. 소득보장이 약속되지 않은 미래의 고령자 층에게 보편적 의료서비스를 제공하는 것이 스마트시티의 주요한 과제로 자리매김할 것이다. 또한 이번 코로나 사태로 전염병에 대한 인식이 크게 향상되었고 특히 밀집된 인구가 거주하는 도시의 경우 문제가 더욱 심화될 수 있다. 지금까지의 스마트시티의 주요 쟁점인 기술, 저출산, 고령화, 질병 논의를 통해 헬스케어 기술의 필요성이 더 이상 삶의 질과 웰빙의 차원에서 그치는 것이 아닌 복지과 의료, 물리적 안전의 개념에서 다뤄지기를 희망한다.

표 1. 본 연구 관련 키워드 정리
Table 1. keyword grouping in smart city

Keyword	Total Occurrences	% Occurrences
Services	10	1.4%
Healthy, Safety and Security	26	3.6%
Utilities	3	0.4%
Energy	17	2.3%
Electricity	3	0.4%
ICT, communication, intelligence, information	188	25.9%
Efficient	24	3.3%
Mobility	14	1.9%
Total	285	39.2%

다양한 분야에서 스마트시티를 구축하기 위해 국가와 기업이 연계하여 기술발전에 투자를 진행하고 있고^[23] 각 도시들을 주요 정책을 상징하여 경쟁력을 확보하고 있는 양상이다^[24]. 이런 와중 헬스케어 분야의 경우, 2018년 4,897억 불 규모의 시장을 가진 IoT 산업에서 가장 큰 디바이스 시장으로 성장하였다^[25]. 또한 본 논문을 통해 다루고자하는 헬스케어 및 SNN의 기술에 대해 연관된 분야를 정리한 것이 표1로 총 연구 동향 중 40%에 육박한다^[2]. 기본 ICT 기반에 헬스케어의 서비스, 건강 및 안전을 포함하고 SNN 기술 특유의 에너지, 전기 효율성, 모바일 디바이스에 적용 가능한 유틸성을 내포하고 있다는 뜻이다.

헬스케어의 특성 상, 미국에서만 한해 150억사 바이트에 달할 정도로 연간 의료데이터가 생성^[26]되지만 많은 경우 센서 및 전자 생체 신호들이 잡음에 민감하고 구조화 되어 있지 않아, 전통적인 머신러닝 방법과 통계학적 방법으로는 특징 추출과 같은 사전 처리 없이 유의미한 결과를 내지 못한다. 하지만 딥 러닝의 경우 데이터가 충분히 많다면, 스스로 패턴을 찾아내는 특성 덕분에 의료데이터 분류 및 예측 문제에 있어 높은 정확도를 보인다^[27]. 이에 MRIs, DNA 배열, EEG 및 ECG 신호 등 생체 신호 분류 문제에 있어 CNN, LSTM, RBM, AE 등 다양한 딥러닝 모델을 활용하는 연구가 많이 진행되고 있다^[28]. 하지만 같은 논문에서 설명하기를, 아직까지 딥러닝을 상용 웨어러블

기기에 적용한 연구는 발견하지 못한다고 말한다. 높은 컴퓨팅 파워를 요구하는 딥 러닝을 모바일 하드웨어에 적용하기에는 큰 과부하나 심각한 병목현상이 발목을 잡는다는 것이다. 따라서 모바일 디바이스에 딥 러닝 아키텍처를 효율적이고 신뢰할 수 있을 정도로 접목시키는 것은 큰 도전과제이며 이를 몇몇 연구에서는 추론 과정을 위해 CPU와 디지털 신호 처리기(DSP)을 개발하거나²⁹⁾ 클라우드 서비스와 연동한 디바이스를 개발하는 식³⁰⁾으로 활로를 모색하고 있다.

하지만 모바일 헬스케어 디바이스에 추론 모델을 적용하기에는, 보다 적은 에너지를 사용하는 저전력 모델이 필요하다고 판단하였고 기본적으로 큰 컴퓨팅 파워를 요구하는 딥 러닝 모델 대신 Spiking Neural Networks 기반의 모델을 제안한다. 생물학적 뉴런의 스파이크들은 시공간 데이터에서 희박하게 발생하고 이벤트에 민감하게 반응한다³¹⁾. 따라서 실제 뇌는 딥 러닝 모델에 비해 전력 사용량 면에서 매우 효율적이며⁸⁾ 이를 구현하고자 하는 것이 SNN의 목표이다. 실제로 SNN은 시공간 데이터를 보다 효율적으로 처리하기 위한 신경 아키텍처를 제공한다³²⁾. 따라서 헬스케어 기술의 처리 과제인 전기적 생체 신호 데이터 분류와 같이 시간적 특성을 내포하는 주파수 데이터 분석에 있어 SNN이 적합한 모델로 딥 러닝을 대체할 수 있을 것으로 판단한다. 또한 저전력을 요구하는 모바일 웨어러블 디바이스로의 변환 역시 SNN이 가능하기에 헬스케어 산업과 SNN 기술의 융합은 발전 가능성이 높은 연구 주제라 생각한다.

이번 장을 통해 스마트시티가 해결해야할 과제들을 제시하였고 이를 통해 헬스케어 기술의 필요성을 언급하였다. 개발도상국이나 부유한 국가나 보편적으로 의료서비스를 전개해야하는 상황 속에서 적용이 어려운 딥러닝 모델의 대안으로 SNN을 제안하였다. 본 논문에서는 스마트시티의 핵심기술로써 SNN을 제안하는 것에만 그치는 것이 아닌 생체 신호인 ECG 부정맥 데이터 셋 분류에 SNN 모델을 적용, 구현하여 실험적 관점에서 SNN의 가능성을 연구하고자 한다.

III. Network Structure

Spiking Neural Networks가 제시되고 많은 시간이 흐르진 않았지만 SNN이 활발히 연구되면서 많은 논문들에 의해 다양한 네트워크 구조들이 제시되었다. Tavaneai et al.(2019)³¹⁾의 논문에 따르면 스파이킹 네트워크 구조를 크게 3가지로 나눌 수 있다.

첫 번째 구조는 기본적인 SNN구조와 이를 여러층

으로 늘린 Deep SNN구조로 가장 대표적인 네트워크로 서론에서 언급한 Brader et al.(2007)¹²⁾, Diehl et al.(2015)¹³⁾가 있다. 이러한 기본 SNN 구조들에서는 2단 혹은 3단의 뉴런층을 사용해 스파이크 정보에서 특징과 패턴을 구분할 수 있음을 보였다. O'Connor and Welling.(2016)¹³³⁾은 Deep SNN에 오차역전파 알고리즘을 적용하여 기존 ReLU 기반 심층신경망에 버금갈 정도의 정확도를 보여주었다.

두 번째 구조는 딥 러닝 분야에서 좋은 성과를 보이는 Deep CNN 구조를 접목한 spiking CNN 구조이다. 초기 레이어에서 커널을 통해 스파이크 속 특징을 추출하고 이를 STDP 학습 규칙과 연동하여 spiking CNN을 구현한다. 위와 같은 구조를 사용한 Kheradpisheh et al.(2018)¹³⁴⁾와 Masquelier and Thorpe.(2007)¹³⁵⁾ 등의 연구에서 높은 정확도를 선보였다.

마지막 구조는 심층신경망(DBN)과 제한된 볼츠만 머신(RBM)에 스파이킹 구조를 접목한 spiking DBN, spiking RBM이 있다. Neftci et al. (2014)¹³⁶⁾는 memoryless stochastic units 대신 IF(interate-and-fire)뉴런 모델을 이용하여 네트워크를 설계하였고 DBN의 경우, Stomatias et al.(2015)¹³⁷⁾의 연구를 통해 제약조건이 많은 하드웨어에도 적합하고 잡음에 강한 spiking DBN을 제시하였다.

이러한 연구들 사이에서 본 논문은, 간단하면서도 강력한 Diehl et al.(2015)¹³⁾ 구조를 참고하여 설계하였다. 따라서 제안하는 네트워크 모델은 그림 1과 같이 두 개의 뉴런층을 가진다. 뉴런과 시냅스 모델은 LIF 모델³⁸⁾을 사용하였고 Input단계에서 포아송 인코딩을 통해 변환된 스파이크가 fully-connected 형태로 흥분성 뉴런층과 연결된다. 이 과정에서 STDP를 통한 학습이 일어나고 흥분성 뉴런층은 같은 사이즈의 억제성 뉴런층과 one-to-one 연결과정을 거친다. 억제성 뉴런층에서는 자신과 연결된 흥분성 뉴런을 제외한 뉴런층을 억제하기 위해 다시 all-to-all 형태로 연결되고 이것을 측면억제(lateral inhibition) 과정이라고 부른다. 마지막 추론 단계에서는 흥분성 뉴런층에 기록

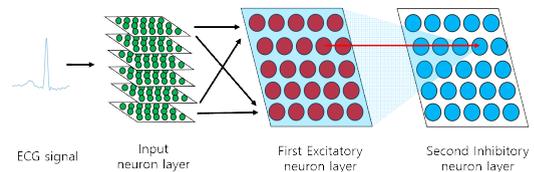


그림 1. 스파이킹 신경망 구조
Fig. 1. The spiking neural networks structure

된 누적 스파이크 값들을 계산하여 입력 데이터에 대한 라벨을 추론한다.

3.1 Leaky Integrate-and-Fire

LIF 모델은 수상돌기를 통해 입력받은 신호를 축적 돌기를 통해 발화하는 뉴런의 시스템을 모방한 모델이다^[38]. 여러 입력과 시냅스 가중치가 곱해진 스파이크들이 뉴런에 쌓이게 되고 이 막 전위(membrane potential)가 문턱전압(threshold voltage)을 넘게 되면 발화하는 구조이다. 이에 대한 수식은 다음과 같다.

$$\tau \frac{dV}{dt} = (E_{rest} - V)Cg_c(E_{exc} - V)Cg_i(E_{inh} - V) \quad (1)$$

여기서 E_{rest} 는 휴지기의 막전위, E_{exc} 와 E_{inh} 는 흥분, 억제성 시냅스의 평형전위, g_e 와 g_i 는 흥분, 억제성 시냅스의 전도도, τ 는 시간상수를 뜻한다. 만약 막전위가 문턱전압 V_{thres} 를 넘으면 스파이크가 발화되고 이내 막전위는 V_{reset} 으로 재설정된다. 이후 몇 밀리 초 동안 뉴런은 불응기(refractory period)에 들어가 스파이크를 발화할 수 없게 된다.

3.2 Poisson Encoding

포아송 인코딩 단계에서는 32bit 혹은 64bit의 float 값을 1bit의 이진 스파이크로 인코딩한다. 이때 미리 설정한 시간으로 시간 축을 추가하기에 $M \times N$ 의 데이터가 포아송 인코딩을 거친다면 $M \times T \times N$ 의 스파이크 배열이 된다. T배만큼 데이터가 늘어나야하기에 포아송 분포를 통해 랜덤한 값들을 생성한다. 포아송 분포에 관한 식은 다음과 같다.

$$f(n;\lambda) = \frac{\lambda^n e^{-\lambda}}{n!} \quad (2)$$

어떤 사건이 일어날 횟수에 대한 기대 값이 λ 이고 그 사건이 n 회 일어날 확률이 $f(n;\lambda)$ 이다.

3.3 Spike-Timing-Dependent Plasticity

Input 층에서 흥분성 뉴런층까지의 모든 시냅스 웨이트를 업데이트하는 STDP는 SNN의 가장 대표적인 생물학적 비지도학습 알고리즘이다. 시냅스 전 뉴런과 시냅스 후 뉴런 간 스파이크 발화 시간 차이를 계산하여 전 뉴런과 후 뉴런이 순차적으로, 근 시간 내에 발화될수록 가중치를 크게 증가시킨다. 반대로 시냅스

후 뉴런이 전 뉴런보다 먼저 발화한다면 가중치를 줄이는 식의 학습이 진행된다. 시냅스 전 뉴런의 가중치 변화 수식은 다음과 같다.

$$\Delta w = -\eta_{pre} x_{post} w^\mu \quad (3)$$

시냅스 후 뉴런의 가중치 변화 수식은 다음과 같다.

$$\Delta w = \eta_{post} (x_{pre} - x_{tar})(w_{max} - w)^\mu \quad (4)$$

η_{pre} 와 η_{post} 는 각각 시냅스 전, 후 가중치 학습속도이고 w_{max} 는 최대 가중치, x_{tar} 는 시냅스 후 뉴런의 발화 순간에 대한 시냅스 전 뉴런의 평균값이다.

IV. ECG Dataset

서론에서 언급하고, Tavanaei et al.(2019)^[31]에서 확인한 기존의 SNN 연구들의 아쉬운 점은 대부분의 연구가 MNIST 데이터를 분별하는데 그친다는 점이다. Tavanaei 정리한 40개의 SNN 관련 논문 중 MNIST 데이터 셋을 사용하는 연구가 무려 34개에 이른다. 나머지 여섯 연구 역시 이미지 훈련 데이터 셋인 CIFAR 계열로 시공간, 주파수 분석에 효율적이라는 SNN^[15]의 특성을 제대로 활용하지 못하고 있는 실정이다. 본 논문에서는 앞서 언급했듯 ECG 데이터를 활용하여 새로운 가능성을 모색하고자 한다.

연구에서 사용한 ECG 데이터는 PhysioNet^[39]의 공공데이터인 MIT-BIH arrhythmia database^[19]를 사용하였다. MIT-BIH arrhythmia database는 총 47명의 환자, 48개의 30분 길이 심장박동 데이터이다. 이를 포인트 단위로 나눈다면 subject별 650,000의 포인트를 가진 데이터이다. DeChazal et al. (2004)^[40]의 분할에 따라 24개의 학습 데이터인 DS1과 24개의 검증 데이터인 DS2로 나누었다.

데이터의 분류는 표 2와 같이 구성하였다. The Association for the Advancement of Medical Instrumentation (AAMI)^[41]의 슈퍼클래스 N, S, V, F, Q로 나누었지만 이중 S를 제외하고 N을 일반, V-F-Q를 부정맥으로 그룹을 만들어 이진 분류하였다. 이 클래스들에 따른 데이터 분포 역시 그림 2에서 확인할 수 있다.

입력 데이터 샘플링은 Sellami et al.(2019)^[42]의 논문을 참고하여 R-peak를 기준으로 앞으로 70, 뒤로 100포인트를 잘라 윈도우 사이즈 170 만큼의 샘플을

표 2. ECG 데이터의 구성과 분포
Table 2. Composition and distribution of ECG dataset

Label	NORMAL		ARRHYTHMIA	
	N (Nonectopic)	V (Ventricular ectopic beat)	F (Fusion beat)	Q (Unknown beat)
DS1 (50,012)	45,805	3,785	414	8
DS2 (47,808)	44,195	3,218	388	7
SUM (97820)	90,000	7,003	802	15

생성하였다. 또한 동일한 논문을 참조하여, 효과적인 검출을 위해 연속한 두 샘플을 하나의 샘플로 이어 붙여 340 사이즈의 샘플을 입력 데이터로 사용하였다.

V. 실험

5.1 실험환경

SNN을 실험하기 위하여 Python 기반의 PyTorch, BindsNet^[43] library를 이용하였다. GeForce RTX 2060 GPU, 16GB RAM, Ubuntu 18.04.5 LTS 환경에서 실험을 진행하였다.

학습데이터로는 50,012개의 샘플 데이터를 가진 DS1, 검증데이터는 47,808개의 샘플 데이터를 가진 DS2를 사용하였다. 각 샘플 데이터는 340길이의 float 데이터이고 각각 정상과 부정맥을 뜻하는 1, 0 라벨이 붙어있다. 흥분성, 억제성 뉴런을 동일한 3,200개로 배치하였고 각 뉴런의 rest, reset, thres 전압을 (-65, -60, -52), (-60, -45, -40)으로 설정하였다. 기존 MNIST 손글씨 데이터 분류의 경우 intensity를 설정하여 데이터의 강도를 조절하지만 ECG의 경우 각 피험자 별 입력 전압이 상이하여 48개의 피험자 데이터 각각 minimax 정규화를 취해주었다. 또한 spike가 이전 연구들만큼 발화하기 위해 샘플 데이터마다 128만큼 곱해주었다. 마지막으로 250ms만큼의 시간을 설정하여 340길이의 샘플 데이터들을 포아송 분포에 따라 250 x 340의 배열로 만들어 입력 데이터로 사용하였다.

5.2 실험결과

데이터의 값을 판별하는 단계에서 3가지 방법을 통해 추론을 실시하였다. 우선적으로 사용한 방법은 Diehl et al.(2015)^[13]을 비롯한 이전의 논문들에서 사용한 방법으로 다음과 같다.

$$infer(A) = \operatorname{argmax}(\sum s_i / n_i)$$

s_i 는 i 라벨로 추정된 흥분성 뉴런에 발화된 스파이크의 수이고 n_i 는 i 라벨로 추정된 흥분성 뉴런의 수이다. 추론방법 B에 대해서는 다음과 같다.

$$infer(B) = \operatorname{argmax}(s_i)$$

추론 B에서는 가장 많이 발화된 뉴런의 추정 라벨에 따라 최종 추론을 결정지었다. 마지막 추론방법 C는 다음과 같다.

$$infer(C) = \operatorname{argmax}(\sum s_i)$$

추론 C의 경우, A의 방법처럼 스파이크 발화 수를 평균화시키는 것이 아닌 흥분성 뉴런 층에서 발화된 누적 스파이크의 총량을 통해 추론하는 방법이다. 스파이크가 터진 뉴런의 수만큼 가중치를 추가해주는 방식은 발화되는 누적 스파이크의 수와 뉴런 개수의 수 차이 때문에 뉴런 개수에 의존적인 성향을 보였고 올바르게 정규화 할 방법이 부재하여 실험에서 제외하였다. 앞서 서술한 3가지 추론방법에 따른 결과가 다음 표 1이고 정상에 대한 정밀도와 민감도, 특이도를 표시하였다.

표 3. 추론방식에 따른 정확도, 정밀도, 민감도, 특이도
Table 3. Accuracy, precision, sensitivity, and specificity according to the inference method

	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)
Infer(A)	83	93	89	13
Infer(B)	87	85	92	8
Infer(C)	89	80	97	6

VI. 결론

본 논문에서는 STDP 알고리즘을 통해 SNN 모델을 설계하고 누적 스파이크 추론 방식의 적용에 따라 성능 및 지표들을 비교해 보았다. 실험결과 A에 비해 B와 C가 정확도에서는 높게 나오지만 다른 지표에서 부족한 모습들을 확인할 수 있었다. 이것의 의미는 모델이 B와 C에서 더 정확히 분류하는 것이 아닌 정상을 추론하는 절대치가 늘어나 정확도가 늘어난 것

럼 보이는 현상으로 보인다. 이에 오히려 정밀도와 특이도가 낮아진 결과를 확인할 수 있다.

실험 중 많은 경우 정확도가 50% 이지만 정상에 대한 정밀도가 99%인 현상을 발견할 수 있었다. 이 현상을 통해 SNN 모델이 잘 정형화된 데이터는 잘 분류하지만 그 밖에 데이터에 대한 유연성은 부족한 모습을 확인할 수 있었다. 이것은 비지도학습인 STDP에 의한 영향으로 추정된다. 이번 실험을 통해 SNN이 MNIST와 ECG 데이터의 결과가 다른 이유를 다음과 같이 추정하였다.

- 데이터 불균형: MIT-BIH database의 경우 정상과 부정맥의 비율이 9:1에 달한다.
- 비정형 데이터: 정형화된 MNIST 데이터와는 달리 MIT-BIH database는 피험자 별 심장박동 측정 과정에서 생긴 잡음, 조건 등에 의해 데이터 내 최대값 5, 최소값 -5와 같이 큰 차이를 보인다.

본 실험을 통해 지금까지 논의되지 않았던 SNN 모델을 이용한 ECG 신호 분석을 수행할 수 있었다. 실험 결과를 통한 추가적인 보충 연구에선, 흥분성, 억제성 뉴런층의 휴지, 초기화, 문턱 전압 값 조절을 통한 결과 값 분석이 필요해 보인다. 또한 smn의 시간적 특성을 활용하기 위해 기존 한 스파이크 단위로 분할한 ECG 신호가 아닌 subject 단위의 raw 데이터를 통한 실험 역시 고려해 볼직하다. 본 연구를 기점으로 다양한 생체 신호 분석과 하드웨어 환경으로 주제를 확산하여 SNN이 모바일 웨어러블 디바이스들과 연동되고, 스마트시티에서 광범위하게 사용될 헬스케어 기술로써 연구가 활발해지길 기대한다.

References

[1] B.-M. Choi, "A study on setting up the concept of smart city through analysis on the term 'Smart'," *J. Korea Contents Assoc.*, vol. 11, no. 12, pp. 943-949, 2011.

[2] ITU-T Focus Group on Smart Sustainable Cities, *Smart sustainable cities: An analysis of definitions*, 2014.

[3] V. Albino, U. Berardi, and R. M. Dangelico, "Smart cities: Definitions, dimensions, performance, and initiatives," *J. Urban Technol.*, vol. 22, no. 1, pp. 3-21, 2015.

[4] H. Chourabi, et al., "Understanding smart

cities: An integrative framework," *2012 45th IEEE Hawaii Int. Conf. Syst. Sci.*, Maui, HI, USA, 2012.

[5] G. E. Hinton, "Learning multiple layers of representation," *Trends in Cognitive Sci.*, vol. 11, no. 10, pp. 428-434, 2007.

[6] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, 2006.

[7] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84-90, 2017.

[8] F. Javed, et al., "Brain and high metabolic rate organ mass: Contributions to resting energy expenditure beyond fat-free mass," *The Am. J. Clinical Nutrition*, vol. 91, no. 4, pp. 907-912, 2010.

[9] W. Maass, "Networks of spiking neurons: The third generation of neural network models," *Neural Netw.*, vol. 10, no. 9, pp. 1659-1671, 1997.

[10] M. Davies, et al., "Loihi: A neuromorphic manycore processor with on-chip learning," *IEEE Micro*, vol. 38, no. 1, pp. 82-99, 2018.

[11] G. Bi and M. Poo, "Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type," *J. Neurosci.*, vol. 18, no. 24, pp. 10464-10472, 1998.

[12] J. M. Brader, W. Senn, and S. Fusi, "Learning real-world stimuli in a neural network with spike-driven synaptic dynamics," *Neural Computat.*, vol. 19, no. 11, pp. 2881-2912, 2007.

[13] P. U. Diehl and M. Cook, "Unsupervised learning of digit recognition using spike-timing-dependent plasticity," *Front. Computat. Neurosci.*, vol. 9, no. 99, 2015.

[14] T. Serrano-Gotarredona, et al., "STDP and STDP variations with memristors for spiking neuromorphic learning systems," *Front. Neurosci.*, vol. 7, no. 2, 2013.

[15] N. Kasabov, et al., "Dynamic evolving spiking

- neural networks for on-line spatio-and spectro-temporal pattern recognition,” *Neural Networks*, vol. 41, pp. 188-201, 2013.
- [16] K. Guo, et al., “From model to FPGA: Software-hardware co-design for efficient neural network acceleration,” *IEEE HCS*, Cupertino, CA, USA, 2016.
- [17] Y. Kim and T. Kim, “An analysis of learning performance changes in spiking neural networks (SNN),” *The J. Convergence on Culture Technol.*, vol. 6, no. 3, pp. 463-468, 2020.
- [18] S. Park and S. Yoon, “Analysis of the training performance and time of SNN by STDP algorithms and spike temporal interactions,” *KIISE Trans. Comput. Practices*, vol. 24, no. 9, pp. 482-486, 2018.
- [19] G. B. Moody and R. G. Mark, “The impact of the MIT-BIH arrhythmia database,” *IEEE Eng. Med. and Biology Mag.*, vol. 20, no. 3, pp. 45-50, 2001.
- [20] United Nations, “2018 revision of world urbanization prospects,” 2018.
- [21] J. Marshall, “Megacity, mega mess...” *Nature*, vol. 437, pp. 312-314, Sep. 2005.
- [22] UNFPA and HelpAge International, “Ageing in the twenty-first century: A celebration and a challenge,” UNFPA and HelpAge International, 2012.
- [23] Y. Han, “The background and promotion of domestic and overseas smart cities,” *J. Electrical World Monthly Mag.*, vol. 473, pp. 26-31, 2016.
- [24] Y. Lee, “Value creation and competitiveness achievement strategies of smart cities,” *J. Korean Regional Sci. Assoc.*, vol. 33, no. 1, pp. 59-68, 2017.
- [25] J. Park, S. Chun, S. Ko, “Internet of Things-based Healthcare Service and Platform Trends,” *KICS Inf. and Commun. Mag.*, vol. 31, no. 12, pp. 25-30, 2014.
- [26] Stanford University School of Medicine, “Stanford Medicine 2017 health trends report. Harnessing the power of data in health,” 2017.
- [27] A. Esteva, et al., “A guide to deep learning in healthcare,” *Nature Med.*, vol. 25, no. 1, pp. 24-29, 2019.
- [28] R. Miotto, et al., “Deep learning for healthcare: Review, opportunities and challenges,” *Briefings in Bioinformat.*, vol. 19, no. 6, pp. 1236-1246, 2018.
- [29] N. D. Lane and P. Georgiev, “Can deep learning revolutionize mobile sensing?,” in *Proc. HotMobile '15*, pp. 117-122, Feb. 2015.
- [30] N. D. Lane, et al., “Deepx: A software accelerator for low-power deep learning inference on mobile devices,” *2016 15th ACM/IEEE IPSN*, Apr. 2016.
- [31] A. Tavanaei, et al., “Deep learning in spiking neural networks,” *Neural Netw.*, vol. 111, pp. 47-63, 2019.
- [32] N. Kasabov, et al., “Evolving spiking neural networks for personalised modelling, classification and prediction of spatio-temporal patterns with a case study on stroke,” *Neurocomput.*, vol. 134, pp. 269-279, 2014.
- [33] P. O’Connor and M. Welling, “Deep spiking networks,” *arXiv preprint*, arXiv:1602.08323, 2016.
- [34] S. Kheradpisheh, et al., “STDP-based spiking deep convolutional neural networks for object recognition,” *Neural Netw.*, vol. 99, pp. 56-67, 2018.
- [35] T. Masquelier and S. J. Thorpe, “Unsupervised learning of visual features through spike timing dependent plasticity,” *PLoS Comput. Biol.*, vol. 3, no. 2, 2007.
- [36] E. Neftci, et al., “Event-driven contrastive divergence for spiking neuromorphic systems,” *Front. Neurosci.*, vol. 7, no. 272, Jan. 2014.
- [37] E. Stomatias, et al., “Robustness of spiking deep belief networks to noise and reduced bit precision of neuro-inspired hardware platforms,” *Front. Neurosci.*, vol. 9, no. 222, 2015.
- [38] L. F. Abbott, “Lapicque’s introduction of the integrate-and-fire model neuron (1907),” *Brain Res. Bulletin*, vol. 50, no. 5-6, pp. 303-304, 1999.

[39] A. L. Goldberger, et al., “PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals,” *Circulation*, vol. 101, no. 23, pp. e215-e220, 2000.

[40] P. de Chazal, M. O’Dwyer, and R. B. Reilly, “Automatic classification of heartbeats using ECG morphology and heartbeat interval features,” *IEEE Trans. Biomed. Eng.*, vol. 51, no. 7, pp. 1196-1206, 2004.

[41] Association for the Advancement of Medical Instrumentation, “*Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms*,” ANSI/AAMI EC38, 1998.

[42] A. Sellami and H. Hwang, “A robust deep convolutional neural network with batch-weighted loss for heartbeat classification,” *Expert Syst. with Appl.*, vol. 122, pp. 75-84, 2019.

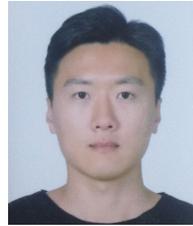
[43] H. Hazan, et al., “Bindsnet : A machine learning-oriented spiking neural networks library in python,” *Front. Neuroinform.*, vol. 12, no. 89, Dec. 2018.

이 충 섭 (Choongseop Lee)



2015년~현재 : 광운대학교 소프트웨어학부 학사과정
 <관심분야> 머신러닝, 계산뇌과학

이 원 규 (Wongyu Lee)



2018년 : 미국 미네소타 대학교 수학과 학사
 2019년~현재 : 광운대학교 지능정보시스템 임베디드SW공학과 석사과정
 <관심분야> 머신러닝, 강화학습, SNN

한 승 우 (Seungwoo Han)



2019년 : 삼육대학교 카메카트 로닉스학과 학사
 2019년~현재 : 광운대학교 지능정보시스템 임베디드SW공학과 석사과정
 <관심분야> 자율주행, 머신러닝, 강화학습

박 철 수 (Cheolsoo Park)



2004년 : 서강대학교 전자공학과 학사
 2006년 : 서울대학교 협동과정 의용생체공학과 석사
 2012년 : 영국 임페리얼 칼리지 런던 박사
 2012년~현재 : 광운대학교 컴퓨터정보공학부 교수

<관심분야> 인공지능, 머신러닝, 생체신호처리