

스마트 인솔의 파라미터에 대한 연구

최영찬¹, 태민우¹, 신수종², 최상일³¹단국대학교 인공지능융합학과 석박사통합과정²단국대학교 컴퓨터공학과 학사과정³단국대학교 컴퓨터공학과 교수njs04288@dankook.ac.kr, 72220500@dankook.ac.kr, shinsjn@naver.com,
choisi@dankook.ac.kr

A Study of Parameters in Smart Insole System

Young-Chan Choi¹, Min-Woo Tae¹, Su-Jong Shin², Sang-Il Choi²¹Dept. of AI-based Convergence, Dankook University²Dept. of Computer Engineering, Dankook University

요 약

스마트 인솔은 멀티 센서가 장착된 디바이스로써, 발바닥의 정보를 추출하는 기기의 특성으로 인해 헬스케어 디바이스로 주목받고 있다. 최근에는 스마트 인솔 내 센서 사양의 증가로 인해 획득 가능한 데이터의 품질이 증가하였으나, 취득한 데이터를 모두 사용하는 것은 통신 대역폭 및 컴퓨팅 파워의 문제가 발생할 수 있다. 본 논문에서는 스마트 인솔 내 파라미터에 대한 분석과 연구를 진행하고, 최적의 파라미터를 제시한다.

1. 서론

보행은 사람 개인의 특성을 잘 나타내는 행동양식으로, 보행 데이터는 예로부터 사용자 인식[1], 질병 조기 진단[2] 등 여러 일에 사용되고 있다. 최근에는 센서의 소형화와 블루투스 기술의 발전으로 더욱 정교한 헬스케어 디바이스가 개발되고 있다. 스마트 인솔은 인솔 내에 압력센서, IMU센서 등 여러 센서가 내장되어 정보를 수집하는 기기로, 보행 데이터를 수집할 수 있는 헬스케어 IoT 기기이다. 기존 보행 분석에 많이 사용되는 매트형식의 보행 분석 장치 혹은 카메라 기반 보행 분석 장치와는 다르게 스마트 인솔은 발바닥에서 직접적으로 데이터를 취득하며, 따라서 측정 시 장소에 구애받지 않는다는 장점이 있으며, 현재 많은 스마트 인솔이 연구용, 소비자용으로 출시되었다. 초기에는 IMU센서만을 이용한 스마트 인솔이 사용되었으나, 최근에는 압력센서를 포함한 스마트 인솔이 사용되는 추세이다. 압력센서의 경우 센서에서 추출되는 데이터의 양도 많고, 샘플링 율에 따라 전력 소모량이 달라지므로[3] 스마트 인솔마다 샘플링 율, 압력센서의 개수, 압력센서의 양자화 레벨등이 모두 다르다. 특히, 웨어러블 디바이스는 높은 성능, 낮은 전력 소비량을 통한

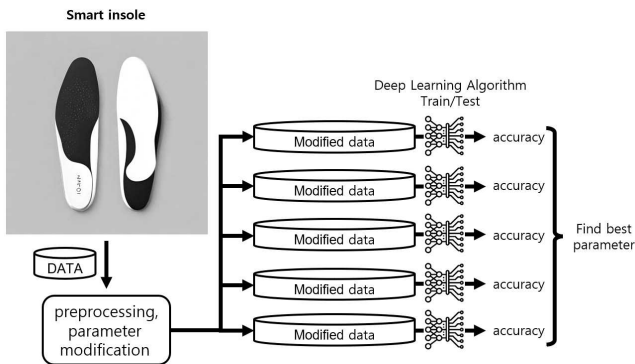
높은 사용 시간, 금액 등을 고려해야 하며, 따라서 상황에 맞는 적절한 성능의 센서 선택이 중요하다. [4]에서는 보행에서 heel-strike와 toe-off 검출에 기여도가 높은 압력센서를 압력센서의 변화량을 기반으로 추천하여 적은 개수의 압력센서를 이용해 높은 heel-strike, toe-off 검출 정확도를 달성 가능하다는 점을 증명했다. 해당 논문은 스마트 인솔의 파라미터와 관련된 유의미한 연구이지만, 오직 heel-strike와 toe-off 검출에만 집중하여 전반적인 보행에 대한 압력센서의 중요도를 구하지는 않았다는 점과 딥러닝 기반 분석이 아닌 점에서 한계점이 존재하였다. 최근 헬스케어 분야에 딥러닝을 결합하여 사용하는 경우가 많아지는 만큼, 이 연구에서는 여러 스마트 인솔의 내부 파라미터를 조정하여 딥러닝 네트워크를 이용한 분류 문제를 해결할 수 있도록 학습을 진행하고, 학습된 정확도에 따라 샘플링 율, 압력 센서의 개수, 압력 센서의 양자화 레벨등 스마트 인솔의 내부 파라미터들이 딥러닝 학습에 끼치는 영향을 알아보고, 최적의 파라미터를 찾아보고자 한다.

2. 실험환경

해당 실험을 위하여 스마트 인솔을 이용하여 데이

터셋을 구성하였다. 사용된 스마트 인솔은 총 2종류의 스마트 인솔로, A사의 스마트 인솔의 경우 100hz의 샘플링 율을 가지고 있으며, 압력센서의 경우 1024단계의 양자화 레벨을 갖는 총 8개의 압력센서가 양발에 고르게 분포하고 있다. B사의 스마트 인솔은 100hz의 샘플링 율을 가지고 있으며, 256단계의 양자화 레벨을 갖는 총 80개의 압력센서가 40개씩 각 발에 고르게 분포하고 있다. 해당 실험에서 사용한 데이터셋의 경우 총 각 사의 스마트 인솔로 수집된 데이터셋으로. A사의 스마트 인솔을 사용하여 수집된 데이터셋은 40명에 대한 걷기, 뛰기, 오르막길 올라가기, 내려가기, 계단 올라가기, 내려가기 등 6종류의 보행 데이터를 포함하는 데이터이다. B사의 스마트 인솔을 이용하여 수집된 데이터셋은 총 9명에 대한 평지 걷기 데이터이다.

A사와 B사의 스마트 인솔로 측정된 데이터셋에는 여러 걸음 데이터가 포함되어 있으며, 하나의 걸음 데이터는 여러 단위 걸음으로 구성된다. 해당 실험에서는 걸음 데이터를 각각의 단위 걸음 데이터로 분리하였다. 단위 걸음으로 분리하기 위해 각 시점에서 왼발의 압력센서의 합을 구하고, 해당 데이터에 가우시안 필터를 사용하여 노이즈를 제거하였다. 가우시안 필터를 적용한 데이터는 미분하여 기울기가 음수에서 양수로 바뀌는 시점을 Heel Strike로 판단하여 단위 걸음으로 나누었다. 이후, 걸음의 길이를 이용하여 이상치를 제거하여 전처리를 마무리하였다.



(그림 1) 전체적인 실험 진행 구성

3. 제안방법

해당 섹션에서는 스마트 인솔의 각 파라미터의 변화에 따른 성능변화를 확인하기 위해 취득된 값에서 파라미터 변화 방법에 대한 설명과 사용된 모델, 성능 비교 방법에 대해 설명한다.


압력센서의 양자화 레벨에 따른 성능 변화를 확인

하기 위하여 A사의 스마트 인솔에서 얻은 압력센서 데이터에서 의도적으로 양자화 레벨을 낮게 변환한 뒤, 해당 데이터를 이용하여 전처리 작업을 진행하였다. 압력센서의 개수에 따른 성능 변화를 확인하기 위하여 B사의 스마트 인솔로 측정된 데이터셋을 사용하였으며, 총 80개의 압력센서에서 일정 비율의 압력센서 데이터를 제거한 후, 전처리 작업을 진행하였다. 이때, 제거하는 압력 센서들은 발바닥의 모든 면적에서 균일하게 선택하여 제거하였다. 샘플링 율에 대한 성능 변화는 원본 데이터에 바로 샘플링 율 변화를 적용하는 것이 아닌, 100hz 기준으로 각 걸음을 나누는 전처리 작업을 진행한 후, 샘플링 율 변화를 적용하였다. 샘플링 율을 가상으로 변환시켜 주기 위하여 연속되는 데이터에서 하나의 시간에 대한 데이터를 선택하고 n개의 이어지는 시간에 취득된 데이터를 제거하는 방법으로 샘플링 율을 낮추었다. 이를 통해서 50hz, 33hz, 25hz의 샘플링 율을 갖는 데이터를 얻을 수 있었다. 또한, 샘플링 율이 단위 걸음을 나누는 알고리즘에 큰 영향을 끼쳐 나누어지는 단위 걸음이 달라지는 문제가 존재하였는데, 해당 문제는 성능에 큰 영향을 미쳐 샘플링 율에 따른 성능 추이를 보기 어렵게 만들었다. 따라서 원본 데이터에서 샘플링 율을 변환한 후, 전처리를 진행하는 것이 아닌, 먼저 전처리를 진행한 후, 샘플링 율 변환을 진행하였다. 샘플링 율 변화에 따른 성능 변화를 확인하기 위하여 데이터의 양이 상대적으로 많은 압력센서를 제외한 가속도 센서와 자이로 센서의 데이터만을 사용하였다.

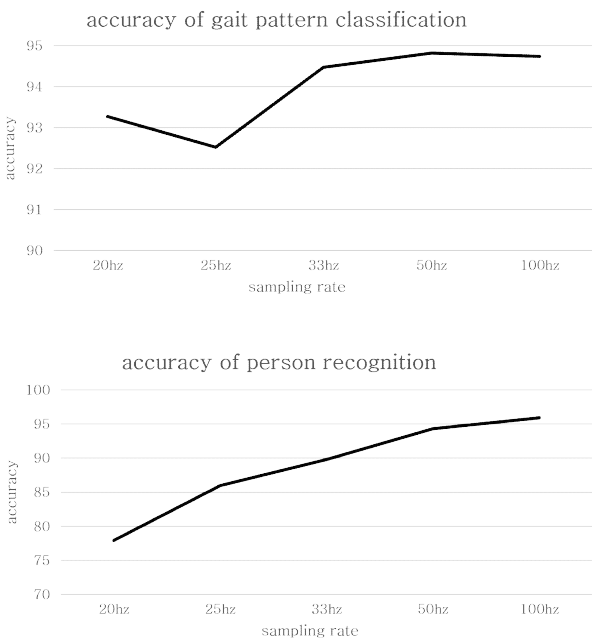
딥러닝 모델의 경우 시공간 데이터 분석에 유리한 Omni-Scale CNN 구조를 사용하였으며, 각 단위 걸음은 길이가 모두 다르므로 최근방 이웃 보간법을 이용하여 128차원의 벡터로 변환하여 딥러닝 모델의 입력으로 사용하였다. 샘플링 율, 압력센서의 양자화 단계, 압력센서의 개수를 변환한 스마트 인솔 데이터는 Omni-Scale CNN을 이용하여 학습을 진행하였으며, 각 학습은 총 20번 반복하여 정확도가 가장 높은 데이터를 선택하였다. 해당 방법을 통해 각 파라미터 값의 변화에 따른 분류성능 변화를 확인할 수 있었다.

4. 실험결과

이 섹션에서는 각 실험에 대한 결과와 그에 따른 해석을 제시한다. 각 실험은 총 20번 반복해서 진행하였으며, 가장 높은 정확도를 기록하였다.




(그림 2) 양자화 레벨에 따른 사람 분류 정확도 추이
 그림2의 결과는 A사의 스마트 인솔을 이용한 데이터셋에서 압력센서의 양자화 레벨에 따른 사용자 분류의 정확도 추이를 나타낸 값이다. 압력센서의 양자화 레벨이 32단계 이상이면 사용자 분류에 대한 성능이 크게 변하지 않는 것을 확인할 수 있으며, 16단계 이하이면 사용자 분류에 대한 성능은 높게 나오는 것을 확인할 수 있었다. 이를 통해 압력센서의 양자화 레벨은 32단계가 적절한 것을 확인할 수 있었다.



(그림 3) 패턴 분류와 사람 분류 문제에서 샘플링 율 별 정확도 추이

그림 3의 결과는 A사의 스마트 인솔로 측정된 데이터에서 가속도 데이터와 자이로 데이터만을 사용하여 사용자 분류와 보행 패턴 분류를 수행한 결과를 나타낸다. 해당 결과는 동일하게 100hz에 가까울수록 정확도가 높아지는 양상을 보였으며, 보행 패턴 분류 문제의 경우 33hz 이상에서 성능이 포화되는 것을 확인할 수 있었다. 이를 통해 샘플링 율의 경우 높을수록 더 많은 유의미한 보행 데이터를 추

출할 수 있음을 확인할 수 있었다.



(그림 4) 압력센서의 개수에 따른 사람 분류 정확도 추이

그림 4의 결과는 B사의 데이터셋에서 압력센서의 개수에 따른 9명의 사용자 분류의 정확도 추이를 나타낸 그래프이다. 총 9명의 인원내 대한 분류성능을 나타내기 위하여 Omni-Scale CNN[5]을 사용하지 않고 하나의 1D 컨볼루션 레이어[6], CBAM모듈[7], 하나의 완전연결 레이어로 이루어진 네트워크를 사용하였다. 또한, 데이터의 경우 33hz로 샘플링 된 데이터를 사용하였으며, 양자화 레벨도 기존의 256단계에서 8단계로 낮추었다. 해당 결과를 통해 압력센서의 개수가 2개인 경우 가장 성능이 낮은 것을 확인할 수 있었다. 압력센서의 개수가 30개, 8개, 5개의 경우 성능 하락이 발생하였다. 이는 딥러닝 모델이 작아 학습에 대한 불안정성으로 인해 학습이 잘 되지 않아 발생한 것으로 보인다.

5. 결론

해당 논문은 여러 실험을 통해 경험적으로 스마트 인솔 내 여러 파라미터에 대한 적정 값을 확인하였다. 양자화 레벨은 32단계 이상에서 성능이 포화되는 것을 확인할 수 있었으며, 샘플링 율은 높을수록 좋은 것을 확인할 수 있었다. 압력센서를 이용한 실험의 경우 완벽한 결론을 얻을 수 없었으나, 압력센서의 개수가 2개일 때 가장 낮은 성능을 보이는 것을 확인할 수 있어, 보행 데이터수집을 위해서는 3개 이상의 압력센서가 권장됨을 확인할 수 있었다.

ACKNOWLEDGEMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 학석사연계ICT핵심인재양성사업의 연구결과로 수행되었음(IITP-2023-RS-2023-00259867)

참고문헌

[1] Choi, Sang-II, et al. "User identification from gait analysis

using multi-modal sensors in smart insole.”, *Sensors* 19.17: 3785, 2019

[2] Pirker, Walter, and Regina Katzenschlager. “Gait disorders in adults and the elderly.” *Wiener Klinische Wochenschrift* 129.3-4: 81-95, 2017

[3] Zhiyuan Zhang, “Insole Systems for Disease Diagnosis and Rehabilitation”, *Biosensors* 13.8: 833, 2023

[4] Chen, Diliang, “Optimal pressure sensor locations in smart insoles for heel-strike and toe-off detection”, *IEEE BioCAS 2022*, Taipei, Taiwan, 2022

[5] Tang Wensi, “Omni-Scale CNNs: A Simple and Effective Kernel Size Configuration for Time Series Classification”, *ICLR 2022*, held online, 2022

[6] Y.Lecun, L. Bottou, Y.Bengio and P.Haffner, “Gradient-based learning applied to document recognition”, *IEEE* 86.11:2278-2324, 1998

[7] Woo, Sanghyun, Park, Jongchan “CBAM: Convolutional Block Attention Module”, *ECCV 2018*, Munich, Germany, 2018