

스마트 인솔의 압력 센서에서 적용가능한 파라미터에 관한 연구

최영찬, 태민우, 김보민, 왕준기, 박준영, 최상일
단국대학교

njs04288@gmail.com, 72220500@dankook.ac.kr, 72210291@dankook.ac.kr,
jaden6171998@gmail.com, wndwls1024@naver.com, choisi@dankook.ac.kr

A Study on the parameters about pressure sensors in smart insole systems

Choi YoungChan, Tae MinWoo, Kim BoMin, Ong ZhunGee, Park JunYeong, Choi Sang-

II*

Dankook Univ.

요 약

본 논문은 스마트 인솔의 압력센서에서 적용가능한 파라미터들에 대해 정확도에 끼치는 영향력에 대한 연구를 통해 최적의 파라미터를 제안한다. 본 논문에서는 1 차원 컨볼루션 네트워크와 장단기 메모리 네트워크에서 주어진 압력 데이터의 압력 단계와 압력 센서 수를 변화시켜가며 모델을 학습시켜 각 모델의 성능 차이를 알아본다. 이후, 도출된 결과를 통해 스마트 인솔에서 압력센서의 개수와 압력 단계에 대한 분석을 제공한다.

I. 서론

보행은 사람 개인의 특징을 잘 나타내는 행동양식으로, 보행 데이터 분석을 통해 사용자 인식[1], 질병 조기진단[2] 등 여러가지 일들을 수행할 수 있다. 과거에는 보행 데이터 수집을 위해 영상 데이터를 많이 활용[3]하였으나, 최근에는 센서의 소형화와 블루투스 기술의 발전으로 인해 보행 데이터를 수집할 수 있는 스마트 인솔을 많이 이용한다.[4] 이러한 스마트 인솔은 블루투스를 통해 데이터를 주고받게 되는데, 해당 방식은 대역폭의 제한을 받는다. 따라서 본논문에서는 인솔들의 파라미터를 변화시키며 실험을 진행하여 효과적으로 보행의 특징을 추출하기 위한 최적의 파라미터를 찾는 것을 목표로 한다.

II. 본론

스마트 인솔에서 추출할 수 있는 데이터로는 압력 데이터, 가속도 데이터, 자이로 데이터가 존재한다. 세가지 종류의 센서들 중, 가속도 데이터와 자이로 데이터는 센서간 정확도의 차이는 크지 않으나, 압력 센서의 경우 센서의 개수, 위치, 압력 단계 등 스마트 인솔별로 모두 다르다. 본 논문에서는 압력 센서가 가질 수 있는 파라미터 중 압력단계와 압력센서의 개수에 초점을 맞춰 실험을 진행하였다. 본논문에서는 총 3 사의 스마트 사용하여 측정한 데이터가 사용되었으며, 데이터는 A 사는 11 명, B 사는 9 명에 대한 걷기 데이터를 사용하였고, C 사는 총 39 명의 걷기 데이터를 사용하였다. A 사와 B 사 두 스마트 인솔의 압력센서의 개수는 총 8 개이고, 샘플링율은 각각 40hz 와 100hz 이며, 각 압력센서는 총 1024 단계를 갖는다. A 사와 B 사와 다르게 C 사의 스마트 인솔의

압력센서의 개수는 총 16 개가 사용되었고, 샘플링율은 100hz 이며, 각 압력센서는 총 3 단계를 갖는다.

본논문에서는 압력센서의 단계를 변화시키기 위해 1024 단계로 입력된 압력센서를 3, 4, 5, 8, 16, 32, 64, 128, 256, 386, 512 단계로 변화시켜가며 실험을 진행하였다. 압력센서의 단계가 조정된 보행 데이터는 압력센서를 이용해 각 걸음별로 나뉘진 후, 87 의 길이를 갖도록 변환되어 네트워크에 입력된다. 본 논문에서는 1 차원 컨볼루션 레이어[5]로 구성된 네트워크와 장단기 메모리로 구성된 네트워크[6]를 특징벡터 추출을 위한 네트워크로 사용하여 파라미터에 따른 성능 변화를 살펴보았다. 1 차원 컨볼루션 네트워크는 필터수가 32 개, 64 개인 2 개의 1 차원 컨볼루션 레이어로 구성되어 있으며, 커널의 크기는 20 으로 설정하였고, 장단기 메모리 네트워크와는 다르게 weight decay 를 0.2 로 설정하였다. 장단기 메모리 네트워크의 경우 총 2 개의 레이어로 구성되었으며, 각 레이어의 dropout 은 0.2 로 설정하였다. 1 차원 컨볼루션 네트워크 혹은 장단기 메모리 네트워크를 거쳐 출력된 특징벡터는 flatten 되어 hidden layer 의 노드 수가 256 개인 다층 퍼셉트론을 거쳐 최종적인 class softmax 값을 구한다.

pressure step	convolution network				lstm network			
	A	B	C	C	A	B	C	C
			(4 pressure sensors)	(8 pressure sensors)			(4 pressure sensors)	(8 pressure sensors)
3	99.1114	85.5461	96.57627119	98.16525424	95.2918	77.415	41.10169492	59.94067797
4	96.7935	92.594			96.9293	83.5529		
5	98.527	94.0244			97.6622	89.0244		
8	97.5472	93.2927			97.7898	89.803		
16	98.72	94.3146			97.4133	94.1652		
32	97.8933	94.652			98.48	96.18		
64	97.467	91.5807			97.4934	95.3078		
128	96.3325	92.5848			97.2823	95.2908		
256	98.4987	92.8764			96.7684	94.7861		
384	97.1594	94.8926			98.4704	94.0184		
512	97.8278	94.763			97.2237	91.9954		
1024	95.4499	90.442			97.7249	91.7899		

Fig. 1. 각 네트워크와 스마트 인솔의 각 압력 단계별 평균 정확도

실험을 총 20 번 반복하여 구한 정확도의 평균값은 Fig1.의 결과와 같다. 압력센서의 단계가 높아질수록 더 높은 정확도가 나오는 경향이 있으나, 압력 단계가 16 보다 높을 때 유의미한 정확도의 차이는 나타나지 않았다. 오히려 압력 단계가 너무 높아지게 되면 정확도가 감소하는 모습도 보였는데, 전처리 단계에서 모든 압력센서의 값의 합을 이용해 걸음을 나눌 때, 높은 압력 단계로 인해 하나의 걸음을 두개의 걸음으로 오인하여 잘못 나뉜 걸음들이 생성되었기 때문이다. 또한 B 사에서 압력센서의 단계를 3 단계로 바꾼 경우, 너무 낮은 압력 단계로 인해 일부 걸음들을 나누지 못하는 모습을 보였고, 이로 인해 정확도가 다른 결과들에 비해 유난히 떨어지는 결과가 나왔다.

압력 단계를 64 단계로 하여 모든 압력 단계에 대하여 동일한 전처리를 진행한 경우 도출된 성능은 Fig2.와 같았다. Fig2. 의 결과를 통해 압력단계가 16 단계보다 높을때 유의미한 정확도의 차이를 얻을 수 없다는 것을 알 수 있었다.

pressure step	convolution network		lstm network	
	A	B	A	B
3	99.11	85.55	95.29	77.42
4	96.79	92.99	96.93	83.55
5	98.53	94.02	97.66	89.02
8	97.55	93.29	97.79	89.80
16	98.72	94.31	97.41	94.17
32	97.89	94.65	98.48	96.18
64	97.47	91.58	97.49	95.31
128	96.33	92.58	97.28	95.29
256	98.50	92.88	96.77	94.79
384	97.16	94.89	98.47	94.02
512	97.83	94.76	97.22	92.00
1024	95.45	90.44	97.72	91.79

Fig. 2. 압력 단계를 64 단계로 고정했을때 각 네트워크와 스마트 인솔의 각 압력 단계별 평균 정확도

압력 센서의 개수는 가장 많은 것이 C 사의 스마트 인솔이 각 발에 8 개로 총 16 개의 압력 센서를 가지고 있어, 이를 이용하여 압력센서의 개수와 정확도 간의 상관관계를 알아보았다. 실험은 두가지 구성으로 진행하였다. 한번은 총 16 개의 압력센서를 모두 사용하여 네트워크 모델별 정확도를 알아보았고, 또 한번은 C 사 외 다른 두 스마트 인솔의 압력센서의 위치에 존재하는 총 8 개의 압력센서를 사용하여 네트워크 모델별 정확도를 알아보았다. 실험결과 각 발에 4 개, 총 8 개의 압력센서를 사용했을 때보다 각 발에 8 개, 총 16 개의 압력센서를 사용했을 때 유의미하게 정확도가 증가하는 것을 확인할 수 있었다. 이를 통해 많은 압력센서를 통해 측정된 데이터에서 더 효과적인 보행 패턴 추출이 가능함을 알 수 있었다.

III. 결론

본 논문에서는 스마트 인솔의 압력 센서에서 적용 가능한 파라미터에 대해서 연구하였다. 실험 결과 압력센서의 단계는 높아질수록 성능이 향상되는 경향은 보이나, 압력센서의 단계가 16 단계 보다 높아졌을 때에는 크게 성능향상이 일어나지 않는 것을 확인할 수 있었다. 또한, 압력센서의 개수는 많을수록 더 높은 성능을 얻을 수 있음을 확인할 수 있었다. 차후 연구에서 더 많은

압력센서를 이용한 스마트 인솔을 이용하여 압력센서의 개수에 따른 성능 변화에 대해 연구할 예정이다.

ACKNOWLEDGMENT

이 논문은 2022 년도 정부(과학기술정보통신부)의 지원으로 정보통신기획평가원의 지원(IITP-2022-0-00899, 멀티 모달 센서가 장착된 스마트 인솔을 이용한 보행 패턴 분석 시스템 개발, IITP-2017-0-00091, 멀티 모달 딥러닝 기반의 바이오 헬스케어 데이터 분석 기술 개발, IITP-2022-00155227, 문맥정보를 이용한 딥러닝 기반의 의료 진단에 활용 가능한 ICT-BIO 융합 기술 개발)의 지원을 받아 수행된 연구임.

참 고 문 헌

- [1] Choi, Sang-Il, et al. "User identification from gait analysis using multi-modal sensors in smart insole." *Sensors* 19.17 (2019): 3785
- [2] Pirker, Walter, and Regina Katzenschlager. "Gait disorders in adults and the elderly." *Wiener Klinische Wochenschrift* 129.3-4(2017): 81-95
- [3] Collins, Rober T., Ralph Gross. And Jianbo Shi. "Silhouette based human identification from body shape and gait." *Preceedings of fifth IEEE international conference on automatic face gesture recognition*. IEEE, 2002.
- [4] Moon, Jucheol, et al. "Can ensemble deep learning identify people by their gait using data collected from multi-modal sensors in their insole?." *Sensors* 20.14 (2020): 4001.
- [5] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998, doi: 10.1109/5.726791.
- [6] Hochreiter, S., & Schmidhuber, J"urgen. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.