

# 스마트 깔창의 센서를 이용한 보행 타입 분류 방법

이성신\*, 장석호°, 최상일°

## Gait Type Classification Based on Deep Learning Using Smart Insole

Sung-Sin Lee\*, Seok-Ho Chang°, Sang-Il Choi°

### 요약

본 레터에서는 스마트깔창에 내장된 압력 센서를 이용하여 보행 데이터를 측정하고, 심층 컨볼루션 신경망(DCNN)을 이용하여 추출한 보행 특징을 바탕으로 보행의 종류를 분류하는 방법을 제안한다. 연속적인 보행에 대한 데이터는 단위 걸음으로 분할된 후 전처리 과정을 거쳐 DCNN의 입력으로 사용된다. DCNN의 출력으로 얻은 특징맵을 이용하여 분류를 위한 최종 완전 연결 네트워크를 구성하여 보행의 종류를 분류하였다. 7종류의 보행 데이터를 실측하여 분류 실험 해 본 결과, 제안한 방법이 88% 이상의 높은 분류율을 보이는 것을 확인하였다.

**Key Words** : Gait type classification, Smart insole, Deep convolutional neural network

### ABSTRACT

We propose a method to classify gait types using a sensor embedded in smart insole. A pressure sensor array was used for gait measurement, and the features of gait pattern were extracted using deep convolutional neural network (DCNN). The measurement data for the continuous walking is divided into unit steps. Then preprocessed data is used as the input of the

DCNN. Using the feature map obtained from the DCNN output, a final complete connection network for classification was constructed to classify the types of gait. Through the experiments for the 7 types of gait, we confirmed that the proposed method showed high classification rate of 88% or more.

### I. 서론

보행은 일상생활의 여러 행동들 가운데 가장 많은 비중을 차지하는 행동의 하나로서, 신체 건강 전반에 걸쳐 중요한 요소이다. 이에 보행에 관한 연구들이 많이 수행되어 왔으며, 특히 보행의 종류를 분류하는 방법은 의료 진단 분야<sup>[1]</sup>를 비롯하여 다양한 종류의 헬스케어 분야<sup>[2]</sup>에서도 많은 관심을 받고 있다.

그동안 보행의 종류를 분류하는 다양한 방법들이 제안되어 왔다. 그러나 많은 경우, 데이터를 측정하기 위해 다수의 센서들을 몸에 부착하거나 제한된 장소에서 측정이 이루어져야 하는 불편함<sup>[3]</sup>과 측정 값의 불안정성<sup>[4]</sup>으로 인해 정확도에 한계가 있었다. 한편, 웨어러블 센서는 데이터를 수집하기 위한 환경적 제약이 적기 때문에 일상생활에서 비교적 쉽게 데이터를 수집할 수 있으며, 옵티컬플로우나 히트맵(heat map) 같은 비디오 데이터에 비해서 용량이 작기 때문에 데이터를 저장 및 처리 부담이 적은 장점이 있다.

이에 본 레터에서는 웨어러블 기기인 스마트 깔창에 장착된 압력 센서를 이용하여 보행을 측정하고 심층 컨볼루션 신경망(deep convolutional neural network, DCNN)<sup>[5]</sup>을 기반으로 보행의 종류를 분류하는 방법을 제안한다. 데이터 수집을 위해 상용 스마트 깔창인 'FootLogger'의 압력 센서를 사용하였으며, 성인 14명이 7종류의 보행을 하면서 실측한 데이터에 대한 실험 결과, 기존의 판별 분석에 의한 방법보다 훨씬 우수한 분류 성능을 보여 주었다.

### II. 연속 보행 데이터의 전처리

3L-Labs Co., Ltd.(Seoul Korea)에서 제작한 FootLogger는 압력의 세기에 따라 0, 1, 2의 값을 측정하는

\* 본 연구는 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행되었으며(No.2018R1A2B6001400), 2018학년도 단국대학교 대학연구비 지원으로 연구되었음.

• First Author : (ORCID:0000-0002-7658-5426)Department of Data Science, Dankook University, leesungsin@gmail.com, 정희원

° Corresponding Author : (ORCID:0000-0002-8982-6954)Department of Computer Science and Engineering, Dankook University, seokho@dankook.ac.kr, 중신희원, (ORCID:0000-0002-8982-6954)choisi@dankook.ac.kr, 정희원

논문번호 : 201808-238-C-RN, Received August 13, 2018; Revised August 22, 2018; Accepted August 22, 2018

8개의 압력 센서로 구성된 센서 어레이(array)를 내장하고 있다. 각 센서들은 100Hz의 샘플링율로 데이터를 측정한다. 보행 시간 동안 연속적으로 측정된 데이터를 단위 걸음 구간들로 분할하기 위해 보행 주기의 stance phase(발이 지면을 디디고 있는 상태)와 swing phase(지면에서 발이 떨어진 상태)를 기준으로<sup>[6]</sup> 단위 걸음의 구간을 분할하여 단위 걸음으로 정의하였다. 단위 걸음에 대한 측정값은 2차원 행렬 형태로 저장되었다(그림 1).

실제 'FootLogger'를 이용한 데이터 측정하였을 때 깔창에 장착된 센서 간 전위차, 발열 등의 여러 요인들로 인해 swing phase임에도 간혹 특정 센서에서 0이 아닌 노이즈 값이 측정되었다. 이러한 노이즈는 한 번의 swing phase를 두 번 발생한 것으로 판단하는 오검출을 초래하여 제안한 방법의 분류 성능을 악화시킬 수 있다.

노이즈를 제거하기 위해, 먼저 왼쪽 발의 압력센서 어레이의 8개의 모든 센서 값의 합이 0이 되는 시점을 'swing phase'의 시작점으로 정의<sup>[6]</sup>하고, swing phase 다음의 swing phase의 시작점은 8개의 압력센서 중에서 2개 이상의 센서에서 0이 아닌 값이 측정되는 시점으로 정의하였다. 만약 swing phase가 시작점에서 stance phase의 시작점 사이에 센서 어레이 측정 값의 합이 1이 나오는 경우 해당 시점의 압력센서 값을 노이즈로 판단하고 해당 센서 값을 0으로 변경하였다.

한편, 측정 시점에 따른 보행 속도의 변이는 보행의 종류를 구분하기 위한 보행 특징을 추출하는데 방해가 된다. 이에 가장 짧은 단위 걸음의 시간을 기준( $t$ ,  $t=63$ )으로 모든 걸음에 대한 길이가 동일하도록 정규화(normalization)하였다<sup>[7]</sup>. 그 결과 압력 센서 어레이

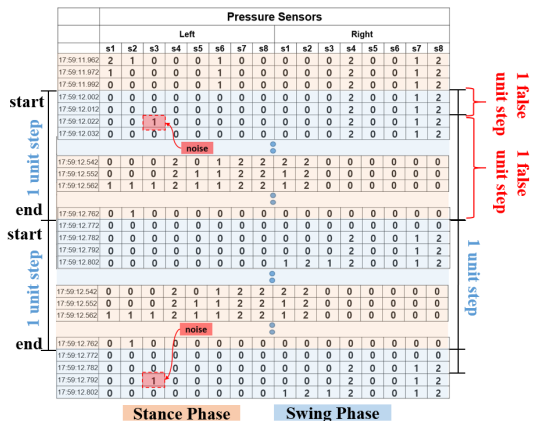


그림 1. 'FootLogger'를 이용하여 측정된 보행데이터 예. Fig. 1. Example of data measured by using 'FootLogger'.

이의 정규화 된 단위 걸음에 대한 측정 값은 63x16의 배열로 변환 되어 1008x1의 벡터로 저장하였다.

### III. 분류를 위한 심층 신경망 설계

#### 3.1 심층 신경망 구조 및 데이터 포맷

그림 2는 제안한 보행 종류 분류 네트워크의 전체 구조를 보여준다. Fig. 3에서 보듯이, 먼저 압력 센서 어레이에 대한 DCNN을 학습 특징맵(feature map)을 추출하고, 특징맵과 보행의 종류 라벨을 출력으로 하는 완전 연결 네트워크(fully connected network)를 구성하여 보행을 종류를 구분하였다.

본 레터에서는 압력 센서 어레이로 측정된 데이터를 II장에서 언급한 전처리 과정을 통해  $t \times S$ 크기로 정규화하여 DCNN의 입력으로 사용하였다 ( $S$ 는 센서 어레이의 센서 개수로 16이고  $t$ 는 63으로 설정하였다). 한편, 보행 종류를 구별하기 위한 보행 특징을 추출하는 데 몇 걸음 정도가 필요한지를 확인하기 위해, DCNN의 입력으로 사용되는 데이터 샘플을 1걸음으로 구성된 것에서부터 걸음 수를 늘려가며 분류 실험을 해 보았다.  $k$ 걸음을 한 개의 보행샘플로 정의한 경우, DCNN의 입력 데이터는  $(t \cdot k) \times S$ 가 된다.

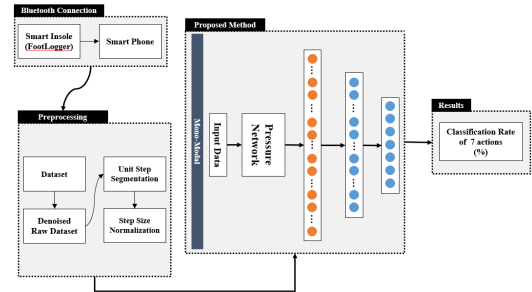


그림 2. 제안하는 방법의 흐름도. Fig. 2. Overall structure of the proposed network.

#### 3.2 컨볼루션 레이어 및 완전연결 레이어 학습

제안한 방법에서 사용된 DCNN은 3개의 컨볼루션 레이어를 포함하고 있다. 각 레이어들은 해당 특징 수준(feature level)의 필터들을 포함하고 있다. 각 컨볼루션 레이어에서 사용한 필터의 개수와 크기, 필터링 스트라이드( $k=2$ 일 때  $s=1$ ,  $k>2$ 일 때  $s=2$ )는 표 1에 요약되어 있다. DCNN의 학습 과정에서 그라디언트 손실(vanishing gradient)을 방지하고 학습의 안정성을 보다 높이기 위해 ReLU(Rectifier Linear Unit)<sup>[8]</sup>함수를 사용하고 활성화 함수 적용 이후에 배치 정규화<sup>[9]</sup>

표 1. 컨볼루션 레이어 구성.  
Table 1. Convolution layers configurations.

	kind of filters	filter size	filtering stride
1 <sup>st</sup> layer	32	16x20	s
2 <sup>nd</sup> layer	64	20x64	s
3 <sup>rd</sup> layer	128	20x128	s

(배치 크기 : 32)를 수행하였다.

벡터 형태의 특징맵은 완전 연결 네트워크의 입력으로 사용된다. 과적합(over-fitting) 문제를 방지하고 일반화(regularization) 성능을 향상시키기 위해 학습시 레이어안에 있는 노드(node)를 드롭아웃<sup>[10]</sup> 비율만큼 무작위로 골라서 삭제한 후 남겨진 노드만을 가지고 학습을 하는 드롭아웃(dropout) 방법을 적용하였다. 최종 출력은 소프트맥스(softmax) 함수를 이용하여 계산하였다.

#### IV. 보행 종류 분류 실험

데이터 수집을 위해 성인 14명으로부터 걷기(WK), 언덕 오르기(RA), 언덕 내려가기(RD), 계단 오르기(SA), 계단 내려가기(SD), 달리기(RUN), 경보(FWK)로 총 7종류의 보행에 대해 데이터를 측정하였다. 전처리 과정을 거쳐 단위 걸음별로 분할하여 정규화한 데이터에 대한 정보는 표 2에 요약되어 있다. 학습과 테스트에 필요한 데이터는 각각 1000개씩 무작위로 뽑아내서 구성하였고, 통계적 신뢰도를 높이기 위해서 위와 같은 작업을 20번 반복하여 평균 분류율을 계산하였다.

학습 과정에서, 손실함수로는 ‘Categorical Cross Entropy’를 사용하였고, 네트워크의 가중치를 최적화하기 위한 방법으로 아담 옵티마이저(adaptive momentum optimizer)<sup>[11]</sup>을 사용하였다(학습율= 0.0001). 제안한 방법의 분류 성능은 판별 분석 기반의 DA-NLDA 방법과<sup>[7]</sup> 비교 평가하였다.

먼저 보행 종류의 분류를 위한 보행 특징을 추출하

표 2. 걸음걸이 측정에 대한 정보.  
Table 2. Information on gait measurement.

gait type	#. of steps	duration	gait type	#. of steps	duration
WK	2,295	3m	SA	747	1m
FWK	2,714	3m	SD	971	1m
RA	1,577	1m	RUN	3,642	3m
RD	1,586	1m			

는데 몇 걸음 정도가 필요한지를 확인하기 위해, 한 걸음에 대한 보행 측정 값으로 구성된 보행 샘플( $k=1$ )에서부터 다섯 걸음의 측정 값을 포함한 보행 샘플( $k=5$ )까지의 인식률을 측정하였다.

그림 3에서 보듯이, 제안한 방법은 실수(real value) 보행 측정 값<sup>[12]</sup>이 아닌 0,1,2의 세 종류의 정수 측정 값만으로도 우수한 분류 성능을 보여 주었다. 모든 경우에 대해 제안한 방법이 DA-NLDA보다 더 높은 분류 성능을 보여 주었으며, 특히 한 걸음으로 구성된 보행 샘플의 경우 DA-NLDA의 분류 성능이 26.10%에 머무른 반면, 제안한 방법은 한 걸음이 포함된 보행 샘플에서도 84.82%의 높은 분류율을 보여 주었다.

한편, 보행 샘플에 포함된 걸음 수가 많을수록 분류율이 증가하다가 ‘4~5 걸음수’에서 증가의 폭이 둔화되는 것을 볼 수 있다. 이는 샘플에 포함된 걸음 수가 많을수록 보행 분류에 유용한 특징을 추출하는 데에 유용한 정보가 많아지지만 4걸음 이상이 포함된 보행 샘플부터는 걸음 수 증가에 대한 추가적인 정보 획득 효과가 사라진다고 볼 수 있다.

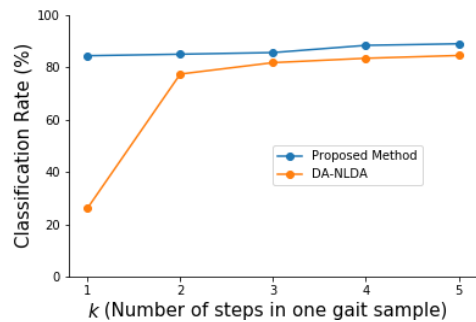


그림 3. 다양한 발걸음을 포함하는 샘플의 분류율.  
Fig. 3. Classification rate for the samples containing various steps.

#### V. 결론

본 논문에서는 스마트 깔창에 장착된 압력 센서 어레이를 이용하여 측정된 데이터로부터 심층 컨볼루션 신경망을 기반으로 다양한 보행의 종류를 분류하는 방법을 제안하였다. 성인 14명이 실측한 데이터에 대한 분류 실험 결과, 한 걸음에 대한 데이터로도 비교적 높은 분류 성능을 보이는 것을 확인하였다. 향후, 보다 다양한 종류의 보행에 대한 데이터에 대한 실험과, 여러 센서 어레이에 대한 네트워크를 결합하여 이중 센서간 시너지를 증대 시키는 방법에 대한 연구를 진행할 예정이다.

## References

- [1] M. W. Whittle, "Clinical gait analysis: A review," *Human Movement Sci.*, vol. 15, no. 3, pp. 369-387, Jun. 1996.
- [2] B. Zhang, S. Jiang, D. Wei, M. Marschollek, and W. Zhang, "State of the art in gait analysis using wearable sensors for healthcare applications," in *IEEE ACIS 11th Int. Comput. and Inf. Sci. Conf.*, pp. 213-218, Shanghai, China, Jun. 2012.
- [3] J. Parkka, M. Ermes, P. Korpiainen, J. Mantyjarvi, J. Peltola, and I. Korhonen, "Activity classification using realistic data from wearable sensors," *IEEE Trans. Inf. Technol. Biomed.*, vol. 10, no. 1, pp. 119-128, Jan. 2006.
- [4] S.-M. Lee, S. M. Yoon, and H. Cho, "Human activity recognition from accelerometer data using convolutional neural network," in *IEEE Int. Conf. BigComp*, pp. 131-134, Jeju island, Korea, Feb. 2017.
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in Neural Inf. Process. Syst.*, pp. 1097-1105, Jan. 2012.
- [6] P. H. Truong, J. Lee, A.-R. Kwon, and G.-M. Jeong, "Stride counting in human walking and walking distance estimation using insole sensors," *Sensors*, vol. 16, no. 6, p. 823, Jun. 2016.
- [7] W. D. Seo, S. S. Lee, W. Y. Shin, and S. I. Choi, "Gait type classification using pressure sensor of smart insole," *J. The Korea Soc. Comput. and Inf.*, vol. 23, no. 2, pp. 17-26, Feb. 2018.
- [8] X. Glorot, A. Bordes, and Y. Bengio, "Deep sparse rectifier neural networks," in *Proc. 14th Int. Conf. Artificial Intell. and Statistics*, vol. 15, pp. 315-323, Apr. 2011.
- [9] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *arXiv preprint arXiv:1502.03167*, Mar. 2015.
- [10] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *The J. Machine Learning Res.*, vol. 15, no. 1, pp. 1929-1958, Jun. 2014.
- [11] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, Dec. 2014.
- [12] P. Zhaoqin, et al., "Human walking pattern recognition based on KPCA and SVM with ground reflex pressure signal," *Mathematical Problems in Eng.*, vol. 2013, Sep. 2013.