

스마트 인솔의 여러 가지 센서 데이터를 이용한 순차적 정보 학습 및 보행 유형 분류

박희찬, 정진원, 왕준기*, 최상일

단국대학교 컴퓨터학과,

*단국대학교 응용컴퓨터공학과

hchan11@naver.com, emperor3236@naver.com, *qq_long@hotmail.com, choisi@dankook.ac.kr

Sequential Information Learning and Gait Type Classification using Various Sensor Data of Smart Insole

Park Hee-Chan, Jung Jinwon, Ong Zhun Gee*, Choi Sang-il

Department of Computer Science and Engineering, Dankook Univ.

*Department of Applied Computer Engineering, Dankook Univ

요 약

본 논문은 스마트 인솔의 여러 가지 센서 데이터를 이용해서 사람의 보행 유형을 분류 할 수 있는 멀티 모달 순환 신경망 모델 프레임워크를 제안한다. 스마트 인솔을 이용하여 측정한 3 가지 센서의 보행 데이터를 변이 제거 및 학습에 적합한 데이터셋으로 구성하기 위해 전 처리 하였고, 개별 센서가 가지고 있는 특징을 좀 더 잘 학습하기 위해 멀티 모달 학습 방법을 사용하며 순차적 정보를 가지고 있는 센서 데이터 분석에 적합한 LSTM 순환 신경망 모델을 사용하였다. 실험 결과, 7가지 보행 유형 분류 성능에 있어서 기존 CNN 기반의 멀티 모달 모델과 비교하여 유의미한 성능을 보여주었다.

I. 서 론

보행은 사람 개인의 특징을 잘 나타내는 대표적인 행동 양상 중 하나로 보행 데이터 분석을 통해 헬스 케어 (Health Care), 다리 관절 질병 조기 진단 [1], 사용자 인식 [2] 등 다양한 분야에 적용되어 왔다. 보행 분석을 위해 선형 판별 분석 방법[3], CNN 기반의 학습 방법 [4]등 다양한 연구가 제안 되었다. 최근 보행 연구에는 센서가 소형화 되고, 몸에 착용할 수 있는 웨어러블 센서가 개발되고, 스마트폰 제어를 통해 원격으로 데이터 서버에 전송할 수 있게 되어 보다 많은 양질의 데이터를 얻을 수 있게 되었다. 본 논문에서는 사람의 보행 유형 분류를 위한 딥 러닝 기반의 프레임워크를 제안한다. 먼저, 스마트 인솔로 취득한 Raw데이터는 환경적 요인으로 인한 변이가 있을 수 있고, 학습에 적합한 데이터로 바꾸기 위하여 전 처리 하였다.

각 도메인에 대하여 학습하여 데이터의 특징을 얻는 방법을 멀티 모달 학습 (Multi-modal Learning)이라고 한다. 센서들의 데이터는 서로 다른 형태로 존재하여 개별 특징을 가지고 있기 때문에 각각의 센서 도메인을 고려하여 학습하면 행동 유형을 좀 더 잘 분류 해준다. 또한, 센서 데이터들은 순차적 (Sequential)으로 측정되어지기 때문에 시간적 정보를 보존하기 위한 학습 모델이 필요하다. 본 논문에서는 순차적 학습에 유리한 LSTM 모델 [5]을 멀티 모달 학습에 사용하였다. 실험 결과 기존 CNN기반의 멀티 모달 모델 [4]과 비교하여 보다 높은 성능을 보여주었다. 본 논문의 구성은 다음과 같다. (1) 보행 데이터 측정 방법을 설명하면서 raw 데이터를 시각화 하여 전 처리 과정을 설명하고, (2) 멀티 모달 LSTM 모델을 설명한 다음, (3) 실험 상세 및 결과를 설명하고 기존 모델과의 비교, 마지막으로 결론으로 끝맺을 한다.

II. 본론

1. 데이터셋 구성 및 전처리 방법




Fig 1. 압력 센서 Raw 데이터와 전 처리 과정 시각화

본 논문에서는 데이터 측정 방법으로 3L Labs 회사의 여러 가지 센서가 장착된 상용 스마트 인솔 'Foot Logger'를 사용하였다. 실험에 사용된 스마트 인솔은 각 발마다 8개의 압력(pressure)센서, 3축 가속도(accelerometer), 3축 자이로(gyro) 3가지 센서가 내장되어 있고, 0.01초 (t=1) 단위로 순차적으로 측정되어진다. 센서 데이터는 총 7가지 보행 유형으로 분류하여 측정되었다. Fig 1은 측정된 Raw데이터의 전 처리 과정을 나타낸 압력 센서 시각화 이미지이다. 시각화 이미지에서 나온 것처럼 압력 센서로 발걸음 패턴을 얻을 수 있다. 데이터 샘플은 왼발 기준으로 인솔의 압력 센서 감지 유무에 따라 Stance Phase와 Swing Phase로 나누어 한 걸음 단위로 정의 하였다. Raw 데이터로부터 얻은 걸음 데이터들은 환경적 변이를 제

거하고, 학습에 적합한 데이터로 사용하기 위해 가장 발걸음이 짧은 길이 ($t=63$)를 기준으로 정규화 했다. 가속도, 자이로 센서 데이터는 압력 센서의 단위 걸음 기준에 맞춰 동일한 시간 구간을 샘플화 하고 정규화 하였다.

2. Multi-modal LSTM Model




Fig 2 LSTM Model 입력 구조

LSTM (Long Short-Term Memory) 모델 [5]은 순차적 정보를 학습할 수 있는 가장 잘 알려진 순환 신경망 모델이다. Fig 2와 같이 센서 데이터는 순차적으로 측정된 데이터이기 때문에 LSTM 모델을 사용하였다. Fig 3은 본 논문에서 제안한 멀티 모달 LSTM 모델을 도식화한 그림이다. 3개의 센서 각각의 도메인을 고려하여 별개의 2-Stacked LSTM 모델로 학습하여 특징 맵 (Feature Map)들을 얻었고, 특징 맵들을 Concatenate 한 뒤에 2층 Fully Connected Layer를 통하여 7개 행동 유형을 Softmax 분류 하였다.




Fig 3. Multi-modal LSTM Model 도식화

3. 실험 상세 및 결과

Table 1 데이터셋 상세

센서	입력 형태	데이터 샘플	학습(Train)	실험(Test)
압력 (pressure)	(63 * k), 16		11,598 / k	1,933 / k
가속도 (acc)	(63 * k), 6	데이터 라벨		7
자이로(gyro)	(63 * k), 6	총 샘플 수 (samples)		13,351

* 걸음 단위 $k = 1, 2, 3$

데이터는 14명을 대상으로 각각 7가지 보행 유형(걷기, 달리기, 계단 올라가기, 계단 내려가기, 언덕 올라가기, 언덕 내려가기, 빠르게 걷기)으로 분류하여 측정, 라벨링 하고, 전 처리 하였다. Table 1은 실험에 사용한 데이터셋 상세이다. 데이터 샘플은 발걸음 당 한 걸음에서 세 걸음($k=1,2,3$)까지 한 샘플로 정의하였다. 한 걸음 기준($k=1$)으로 총 13531개의 데이터

샘플로 이루어져 있으며 한 걸음부터 세 걸음($k=3$)까지 한 샘플을 정의하였다. 기존 논문과 비교하기 위하여 7번의 교차 검증 (7 Cross Validation) 샘플링 한 다음, 20 epoch, 0.001 learning rate 파라미터로 주교 모델을 학습하여 5번씩 반복 실험 하였다. 테이블 2의 실험 결과에 따르면 동일한 조건 내에서 CNN 기반의 멀티 모달 모델 [4] 보다 성능의 향상이 있는 것을 확인 할 수 있었다.

Table 2 실험 결과

실험 방법	걸음 단위 (k)	1	2	3
7-Cross Validation	모델	Average Accuracy		
	CNN-Based	93.93%	94.12%	93.96%
	proposed	94.90%	94.25%	93.64%

III. 결론

본 논문에서는 스마트 인솔을 이용해 측정된 센서 데이터들을 전처리 하고 학습하는 LSTM 기반의 멀티 모달 모델을 제안 하였다. 실험 결과, CNN 기반의 모델과 비교하여 순차 학습에 대한 유의미한 경쟁력이 있음을 확인 했다. 현재 실험에서는 일정한 Stance Phase-Swing Phase를 센서 압력 감지에 따른 규칙에 대해서 발걸음을 구분하고 있다. 차후 연구에서는 보다 높은 발걸음 패턴 구분을 위해 발걸음 단위를 정의하는 부분도 네트워크화 해서 학습해 볼 예정이고, CNN과 앙상블 기법을 통해 순차적 정보 및 국소적 위치에 대한 정보도 학습하여 실험할 예정이고, 학습 시에 각 센서의 특징 맵을 Concatenate하는 부분을 통해 개별 도메인의 특징을 얻어 분류하는 부분을 개선하여 특징 맵 간에 유사도(Similarity)를 얻는 방법으로 Attention 기법 [6]을 연구할 예정이다.

ACKNOWLEDGMENT

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학 사업(2017-0-00091)과 글로벌 핵심인재양성지원사업의 연구결과로 수행되었음(No.2020-0-01463)"

참 고 문 헌

- [1] Pirker, Walter, and Regina Kitzschlager. "Gait disorders in adults and the elderly." *Wiener Klinische Wochenschrift* 129.3-4 (2017): 81-95.
- [2] Choi, Sang-II, et al. "User identification from gait analysis using multi-modal sensors in smart insole." *Sensors* 19.17 (2019): 3785.
- [3] Choi, Sang-II, et al. "Gait type classification using smart insole sensors." *TENCON 2018-2018 IEEE Region 10 Conference*. IEEE, 2018.
- [4] Lee, Sung-Sin, Sang Tae Choi, and Sang-II Choi. "Classification of gait type based on deep learning using various sensors with smart insole." *Sensors* 19.8 (2019): 1757.
- [5] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9.8 (1997): 1735-1780.
- [6] Nam, Hyeonseob, Jung-Woo Ha, and Jeonghee Kim. "Dual attention networks for multimodal reasoning and matching." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017.