

# CNN을 이용한 족저압 기반의 무릎관절 각도 예측 및 정확도 향상에 대한 연구

공예은\*, 정아현\* 정승민\*\*, 호종갑\*\*, 김영\*\*\*, 민세동\* \*\*

순천향대학교 의료IT공학과\*, 순천향대학교 소프트웨어융합학과\*\*

순천향대학교 BK21 Four Well-Life실현을 위한 빅데이터 혁신인재 양성 교육연구단\*\*\*

## A study on plantar pressure based knee joint angle prediction and accuracy improvement using CNN

Ye Eun Kong\*, A Hyun Jung\*, Seungmin Jeong\*\*, Jong Gab Ho\*\*, Young Kim\*\*\*, Se Dong Min\* \*\*

Department of Medical IT Engineering, Soonchunhyang University\*

Department of Software Convergence, Soonchunhyang University\*\*

BK21 FOUR Well-Life Big Data Institute, Soonchunhyang University\*\*\*

**Abstract** - 보행 시 족저압과 무릎관절 각도는 서로 연관되어 있고, 무릎관절 각도는 보폭과 보행 속도 등을 분석할 수 있는 중요한 보행 지표이다. 본 연구에서는 총 6명의 건강한 피험자를 모집하여 보행 시 족저압 데이터와 왼쪽 무릎 각도를 수집하였고, 2차원 CNN 회귀 모델을 사용하여 데이터를 분석하였다. 인공지능 모델을 통해 왼발의 족저압 입력(single plantar pressure; SPP)과 유각기 시점의 왼발 족저압을 입각기 시점의 오른발 족저압으로 대체 입력(double plantar pressure; DPP)하여 왼쪽 무릎각도를 유추하였다. Mean Absolute Error(MAE), Mean Relative Error(MRE), R<sup>2</sup> Score 값을 통해 SPP와 DPP의 상관성과 정확도를 분석하였다. 그 결과, DPP 방법을 사용하였을 때 모델의 예측 정확도가 2배 가량 높아지는 것을 확인하였다. 본 연구 결과를 통해 족저압만으로 유각기를 포함한 전 보행주기의 무릎관절 각도를 예측할 수 있음을 확인하였고, 향후 보폭 및 보행 속도를 유추할 수 있는 시스템을 개발할 수 있을 것으로 기대된다.

### 1. 서 론

신경계 및 근골격계 질환은 무릎관절 각도에 심각한 영향을 미치며[1], 무릎관절 각도의 분석을 통해 보행 장애 지표인 보폭 감소, 보행 속도 감소 등을 추정할 수 있다[2]. 이러한 무릎관절 각도 데이터를 얻는 대표적인 방법으로 RGB-D 이미지를 이용하는 방법이 있는데, 그 중 Azure Kinect는 트레드밀 보행에서 시상 무릎관절 좌표를 추적하는데 우수한 성능을 보인다는 연구가 있다[3].

한편, 보행을 분석하기 위한 데이터로는 가속도, 족저압, 이미지 등이 있다. 그 중 족저압 데이터는 가속도, 이미지 데이터와는 달리, 신발 내 인솔 센서를 통해 측정할 수 있어 편리하며, 프라이버시 문제에서 자유롭다. 따라서 본 연구에서는 족저압만을 이용하여 무릎관절 각도를 예측하고자 하였다. 그러나, 기존의 관련 연구를 보면 유각기에서 족저압 정보가 없어 정확도가 떨어지는 것을 확인하였고[4], 이를 해결하고자 유각기에서 반대쪽 발의 족저압 정보를 활용하여 분석을 진행하였다.

본 연구에서는 Azure Kinect를 이용한 RGB-D 이미지로부터 무릎 관절 각도를 계산하고, F-scan으로부터 족저압 데이터를 측정하여 인공지능 모델 기반의 보행 시 족저압 데이터로 무릎관절 각도를 추정하는 연구의 가능성을 확인하고자 한다.

### 2. 방 법

#### 2.1. 피험자

족저압 및 무릎관절 각도 데이터를 수집하기 위해 정상보행을 수행함에 있어 어려움이 없고 신경계, 근골격계 장애가 없는 건강한 20대 피험자 6명(남 3명, 여 3명)을 모집하였다. 피험자들의 평균 나이는 24 ± 2.3 세였고, 평균 신장은 165 ± 9 cm였으며, 평균 체중은 67.4 ± 17.8 kg였다. 평균 신발 사이즈는 250.8 ± 16.9 mm이며, 평균 보행 속도는 3.83 ± 0.26 km/h였다.

#### 2.2. 데이터 수집

족저압 데이터는 F-Scan(Tekscan, USA) 족저압 측정 센서를 이용하여 수집하였고, 보행 시 RGB-D 이미지를 수집하기 위해 Azure Kinect DK(Microsoft, USA)를 사용하였다. 족저압 데이터는 100 Hz Sampling rate로, RGB-D 영상은 20 fps로 수집하였다.

실험 전, 피험자에게 트레드밀 사용법을 충분히 숙지시키고, 실험 방법 및 주의사항을 설명하였다. 피험자는 f-scan 족저압 측정 센서가 내장된 신발을 착용하고, 무릎 관절이 잘 추적될 수 있도록 반바지를 착용하였다. 데이터를 측정하기 전에, 피험자는 본인에게 편안한 트레드밀 속도를 선택하였고, 그 속도에서 보행이 안정화 된 후 측정을 시작하였다. 이 때, Kinect는 트레드밀로부터 1 m 거리 떨어진 곳에, 1 m 높이에 고정하여 RGB-D 영상을 촬영하였다[5]. 피험자는 2 분 동안의 보행 실험을 2회 진행하였으며, 각 보행 실험 사이에 4 분 동안 앉아서 충분한 휴식을 취하도록 하였다.

#### 2.3. 데이터 전처리


왼쪽 무릎관절 각도 데이터를 얻기 위하여 RGB-D 영상에서 left hip, left knee, left ankle 관절의 x, y 좌표를 추출하였다. 이 관절 좌표들을 이용하여 세 점 사이의 각도를 계산하여 무릎관절 각도를 추출하였다.

그 후, 20 fps로 측정된 왼쪽 무릎관절 데이터는 인공지능 모델의 학습을 위하여 보간법으로 리샘플링하여 100 Hz로 측정된 족저압 데이터와 샘플 수를 일치시켰다.

본 연구에서는 보행 중 족저압이 측정되지 않는 유각기 시점에서 왼발 족저압 데이터를 해당 시점의 오른발 족저압 데이터로 대체하여 인공지능 모델의 입력값으로 사용하였다. 왼발의 유각기 시점에서 오른발은 입각기였기 때문이다.

#### 2.4. 데이터 분석

족저압 이미지를 입력값으로 사용하여 무릎관절 각도를 예측하기 위해 이미지를 통한 분류, 회귀 성능이 좋은 것으로 알려진 2차원 CNN 회귀 모델을 사용하였다[6]. 본 연구에서 사용한 CNN 모델의 구조는 <그림 2>와 같다.



<그림 2> 2차원 CNN 회귀 모델 구조

CNN 모델의 입력 값으로는 59×21 족저압 이미지 데이터를 사용하였다. 입력 값과 출력 값 사이에는 2차원 7×7, 5×5, 3×3 Convolutional layer가 있는데, 각 Convolutional layer 사이에는 2×2 Max-Pooling layer가 있다. Convolutional layer의 특징 맵은 128개이며, 활성화함수는 swish 함수를 사용하였다. 이를 거쳐 추출된 특징은 Flatten layer에서 1차원 배열로 만들어지고, CNN 모델은 5층의 Fully-Connected layer를 통해 epoch을 50으로 하여 회귀 학습했다. 6명의 피험자로부터 얻은 144,000 개의 족저압 데이터를 무작위로 섞어 8:2 비율로 학습 데이터와 테스트 데이터로 나누어 학습 데이터를 통해 모델을 학습하고, 테스트 데이터로 예측 결과를 검증하였다.

테스트 데이터 분석을 위해 CNN 모델의 무릎관절 각도 예측 결과를 Mean Absolute Error(MAE), Mean Relative Error(MRE), R<sup>2</sup> Score를 통해 나타내었다. 또한, 유각기 시점에 있는 다리의 족저압을 입각기 시점에 있는 반대측 족저압으로 대체 입력하여 유각기 측 무릎각도 예측의 정확도를 확인하였다.

### 3. 결과 및 고찰

#### 3.1. 결과

족저압 이미지를 입력값으로 한 CNN 모델의 예측 결과는 <표 1>과 같다. 'SPP(Single Plantar Pressure)'는 왼발 족저압 데이터만을 입력으로 사용한 방법이고, 'DPP(Double Plantar Pressure)'는 유각기 시점의 왼발 족저압 데이터를 입각기 시점의 오른발 족저압 데이터로 대체하여 입력하는 방법이다.

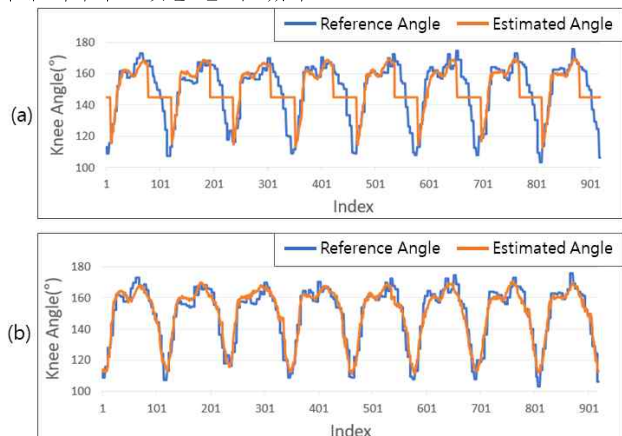
<표 1> 무릎관절 각도 예측을 위한 입력 값으로 왼쪽 족저압만을 사용했을 때와 오른쪽 족저압을 함께 사용했을 때 결과

	SPP	DPP
MAE	9.285 ± 9.604°	2.984 ± 2.906°
MRE	6.665 %	2.048 %
R <sup>2</sup> Score	0.462	0.948

\* SPP: Single Plantar Pressure, DPP: Double Plantar Pressure

두 방법의 R<sup>2</sup> Score를 비교해 보면, SPP 방법을 사용했을 때 0.462, DPP 방법을 사용했을 때 0.948으로, DPP에서 약 두 배 높게 나타난 것을 확인할 수 있다. 또한, 평균 오차를 나타내는 MAE는 SPP에서 9.285 ± 9.604°, DPP에서 2.984 ± 2.906°였으며, MRE는 SPP에서 6.665 % DPP에서 2.048 %로 오차가 절반 이상 감소했음을 알 수 있다.

<그림 3>은 Kinect로 측정된 Reference Angle과 CNN 모델이 예측한 Estimated Angle을 함께 나타낸 그래프이다. (a)는 SPP 방법으로 다리 각도를 예측한 결과이고, (b)는 DPP 방법으로 다리 각도를 예측한 결과 그래프이다. (a)에서는 모델이 정확한 각도가 아닌 평균적인 각도를 예측하는 것을 확인할 수 있다. 이에 반해 (b)에서는 전 보행주기 동안 무릎 각도를 유의미하게 예측하는 것을 볼 수 있다.



<그림 3> Reference Angle과 CNN 모델이 예측한 Estimated Angle을 나타낸 그래프  
(a) SPP 방법 (b) DPP 방법

### 3.2. 고찰

SPP방식과 DPP 방식의 무릎관절 각도 예측 성능을 비교한 결과, DPP 방식의 예측 성능이 약 두 배 이상 정확한 것으로 나타났다. 이는 <그림 3>에서 볼 수 있는 것과 같이 SPP 방식은 유각기 시점에서 어떠한 정보도 없이 평균적인 무릎관절 각도를 예측하기 위해 학습했기 때문으로 보인다. 이와 달리 DPP 방식은 반대편 발의 족저압을 통해 보행의 진행과 무릎 움직임을 예측할 수 있었기 때문으로 사료된다.

### 4. 결론

본 연구에서는 CNN 회귀 모델을 사용하여 보행 시 족저압으로 무릎관절 각도를 예측하였다. 이때, 왼쪽 발이 유각기일 때 오른발 족저압을 입력 데이터로 사용하는 방식을 제시하였으며, 이는 왼발 족저압만 사용할 때보다 예측 정확도가 높음을 검증하였다.

제시한 방법을 통해 예측 성능 개선을 이뤄냈다는 장점에도 불구하고, 본 연구에는 RGB-D 영상을 통해 계산한 무릎 각도가 ground truth 관절 각도와 일치하는지 검증하지 못했다는 한계가 있다. 향후 연구에서는 ground truth 무릎관절 각도를 통해 모델을 학습/검증하고 보행 장애가 있는 피험자의 데이터를 모델에게 학습시킬 예정이다. 이를 통해 족저압 데이터만으로 보행 시 무릎관절 각도 변화를 추정할 뿐 아니라, 질환으로 인한 보폭 및 보행 속도의 변화를 관찰할 수 있을 것으로 기대한다. 이는, 질환 예측 및 재활 훈련 분야의 핵심적인 지표로 활용되는 연구에 기여할 수 있을 것으로 기대한다.

#### 감사의 글

본 연구는 2021년 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업의 연구결과로 수행되었음(2021-0-01399).

이 논문은 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2021R111A3059769).

이 논문은 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2018R1D1A1B07050037).

#### [참고 문헌]

- [1] Zhang, Li, et al. "Knee joint biomechanics in physiological conditions and how pathologies can affect it: a systematic review." Applied bionics and biomechanics 2020, 2020
- [2] Mentiplay, B. F., Banky, M., Clark, R. A., Kahn, M. B., & Williams, G., "Lower limb angular velocity during walking at various speeds", Gait & posture, 65, 190-196. 2018
- [3] Yeung, Ling-Fung, et al. "Effects of camera viewing angles on tracking kinematic gait patterns using Azure Kinect, Kinect v2 and Orbbec Astra Pro v2." Gait & Posture 87 : 19-26, 2021
- [4] Choeum, V., Kim, Y., & Min, S. D., "A Convolution Neural Network Approach to Access Knee Joint Angle Using Foot Pressure Mapping Images: A Preliminary Investigation", IEEE Sensors Journal, 21(15), 16937-16944, 2021
- [5] Zou, Q., Ni, L., Wang, Q., Li, Q., & Wang, S., "Robust gait recognition by integrating inertial and RGBD sensors." IEEE transactions on cybernetics, 48(4), 1136-1150, 2017
- [6] O'Shea, Keiron, and Ryan Nash. "An introduction to convolutional neural networks." arXiv preprint arXiv:1511.08458, 2015