

LSTM을 이용한 족저압 센서 압력 예측 연구

김민성, 성은충, 주백석*

국립금오공과대학교

minsang125@kumoh.ac.kr, tjddmschd@kumoh.ac.kr

*bschu@kumoh.ac.kr

A Study on the Prediction of Insole Sensor Pressure Using LSTM

Minseong Kim, Eunchong Seong, Beaksuk Chu*

Kumoh National Institute of Technology

요약

본 연구는 착용형 근력 증강 로봇의 동작 예측을 목표로, 족저압 센서에서 수집된 시계열 데이터를 기반으로 LSTM(Long Short-Term Memory) 모델을 활용하여 발에 가해지는 압력의 총합을 예측하는 방법을 제안하였다. 연구에서는 일상생활에서 빈번히 수행되는 걷기 동작과 하체 근력에 중요한 스쿼트 동작을 선정하여 데이터를 수집하였다. 각 동작당 200세트의 데이터를 Moticon사의 Opengo 족저압 센서를 사용해 수집하였으며, 이 데이터를 바탕으로 LSTM 모델을 설계하고 학습하였다. 본 연구에서 개발한 LSTM 모델은 3개의 LSTM 레이어로 구성되었으며, 데이터를 표준화한 후 80%는 훈련 데이터로, 20%는 테스트 데이터로 분류하여 학습을 진행하였다. 모델의 성능을 평가하기 위해 MAE(Mean Absolute Error)와 예측 정확도를 사용하였으며, 걷기 동작의 경우 MAE는 23.3N, 스쿼트 동작의 경우 16.6N으로 나타났다. 또한, 예측 정확도는 걷기 동작에서 91.4%, 스쿼트 동작에서 95.4%로 매우 높은 예측 성능을 보였다. 향후 연구에서는 다양한 동작을 추가하고, 압력 분포와 압력 중심 좌표를 기반으로 한 동작 예측을 적용함으로써 예측 정확도를 더욱 향상시킬 계획이다.

I. 서론

착용형 근력 증강 로봇은 각종 현장에서 작업자의 근력을 보조하기 위해 인체에 착용하여 인간의 동작을 보조하거나 증강하는 로봇을 의미한다. 이러한 로봇은 사용자의 동작을 인식한 후 정보처리를 통해 근력 증강이 이루어져 제어 지연이 발생한다. 그러나 제어 지연으로 실시간 제어에 한계가 있을 수 있으며, 이를 해결하기 위해 사용자의 동작을 미리 예측하는 기술이 필요하다. 착용형 근력 로봇과 인공지능을 활용한 연구들이 활발히 진행되고 있다. [1] 본 연구는 족저압 센서를 통해 수집된 시계열 데이터를 기반으로 사용자의 동작을 예측하는 모델을 개발하는 것을 목표로 하였다. 딥러닝 알고리즘인 LSTM(Long Short-Term Memory) 모델을 이용하여 패턴을 학습하고 미래의 압력을 예측하였다.

II. 본론

2-1 동작 예측을 위한 LSTM 배경

LSTM(Long Short-Term Memory)은 시계열 데이터를 다룰 때 특히 유용한 딥러닝 모델이다. 일반적인 RNN(Recurrent Neural Network)은 장기 의존성 문제가 발생할 수 있어, 긴 시간에 걸친 시계열 데이터를 학습시키는 데 한계가 있지만, LSTM은 이러한 한계를 해결한 모델로서 긴 시

스 데이터를 처리하고 장기 의존성 문제를 해결하는 데 효과적이다. 본 연구에서는 LSTM 모델을 활용하여 사용자의 발에 가해지는 압력의 총합을 예측하는 모델을 설계하였다. 걷기와 스쿼트 동작이 시간에 따라 압력 패턴이 변화하며, 이를 통해 동작 패턴을 파악할 수 있다. 이를 바탕으로, 압력 변화를 예측함으로써 동작의 연속성을 사전에 예측하고자 하였다.

2-2 데이터 수집 및 학습

본 연구에서는 데이터를 측정 센서로 Moticon사의 족저압 센서 Opengo를 사용하였다. Opengo의 사양은 Table 1, 센서의 위치는 Fig 1과 같다. 센서에는 압력 센서 16개, 기울기를 측정할 수 있는 3축의 IMU 센서 및 각속도 센서가 내장되어 있다. 측정된 데이터는 스마트폰과 실시간 블루투스 통신으로 전송되며, 스마트폰에 저장된 데이터는 와이파이를 통해 PC로 전송된다. 측정된 압력 값은 각 압력 센서의 면적과 스케일링 팩터를 고려하여 총합이 식(1)을 통하여 계산된다.

$$F = \sum_{i=1}^{16} p_i \cdot A_i \cdot k_i \quad (1)$$

여기서 p_i 는 각 압력 센서에서 측정된 압력 값, A_i 는 각 센서의 면적, 그리고 k_i 는 각 센서의 스케일링 팩터 값이다. [2]




Fig 1. Opengo sensor

Table 1. Specification of Opengo Insole Sensor

Sampling rate	100 hz
Number of pressure sensors	16개
Maximum measurable weight	120 kg

족저압 센서의 데이터 측정을 위해 걷기와 스쿼트 두 가지 동작을 선정하였다. 걷기는 일상생활에서 가장 빈번히 수행되는 기본적인 운동 형태이며, 스쿼트는 하체 근력을 사용하는 대표적인 동작이다. 각 동작에서 발생하는 압력의 특징한 파형을 바탕으로, 2분씩 데이터를 측정하여 각 동작당 200세트의 데이터를 수집하였다. Fig 2는 각 동작 중 한쪽 발에 가해지는 압력의 총합을 시각화한 것이다. 걷기 동작의 경우, 왼쪽 발뒤꿈치가 땅에 닿을 때부터 다시 닿기까지 약 2초가 소요되며, 발이 땅에 닿으면 압력이 급격히 증가하고, 발이 떨어지는 순간 다시 압력이 증가하였다가 압력이 감소하게된다. 스쿼트 동작의 경우 앉았다 일어날 때까지 약 2초가 걸리며, 앉을 때 반동으로 인해 압력이 700N 이상으로 급격히 상승하고, 일어날 때는 300N ~ 400N 사이의 압력을 나타낸다.




Fig 2. Measured data graph

본 논문에서 사용한 LSTM 모델은 python을 사용하여 구현하였다. 설계된 LSTM 모델은 3개의 레이어로 구성되었으며, 학습은 20 epoch로 설정하였다. 데이터는 훈련데이터 80% 나머지 20%는 테스트 데이터로 분류하였으며 데이터는 표준화하였다. Fig 3은 10초간의 입력 데이터를 기반으로 2초 후의 압력을 예측한 결과를 나타낸 그래프다.





Fig 3. Motion prediction result graph

모델의 성능을 평가하기 위해 MAE(Mean Absolute Error)를 사용하였다. MAE는 실제 데이터와 예측 데이터 사이의 절대 오차의 평균을 나타내며 식(2)를 통해 계산된다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

걷기 동작에서 MAE는 23.3N, 스쿼트 동작에서 MAE는 16.6N으로 나타났다. 이는 LSTM 모델이 걷기 동작에서는 평균적으로 23.3N, 스쿼트 동작에서는 16.6N의 오차를 보였음을 의미한다. 예측 정확도는 실제 값과 예측 값의 차이가 설정된 오차 범위(실제 값의 5%)내에 있을 경우 이를 정확한 예측으로 간주하여 계산하였다. 식(3)은 예측 정확도를 계산하는 식이다.

$$Accuracy = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}} \times 100 \quad (3)$$

걷기 동작의 경우 예측 정확도는 91.4%, 스쿼트 동작의 경우 95.4%로 나타났다.

III. 결론 및 향후 연구

본 연구는 착용형 근력 증강 로봇 사용자의 동작 의도를 사전 예측하기 위해, 족저압 센서를 활용한 데이터를 바탕으로 LSTM을 이용한 예측 모델을 제작하였다. 실험 결과, 걷기 동작의 MAE는 23.3N, 스쿼트 동작의 MAE는 16.6N으로 나타났으며, 예측 정확도는 걷기 동작은 91.4%, 스쿼트 동작은 95.4%로 높은 예측률을 나타내고 있었다. 향후 연구에서는 동작의 다양성을 확장하여 압력분포나 압력 중심 좌표를 통한 동작 예측을 시도하여 정확도를 비교하는 연구를 진행하려고 한다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신부 및 정보통신기획평가원의 ICT 혁신인재 4.0 사업의 연구결과로 수행되었음 (No. IITP-2024-2022-00156394).

참 고 문 헌

- [1] Tang, J, et al., "Seizure detection using wearable sensors and machine learning: Setting a benchmark." *Epilepsia* Volume 62, pp 1807-1819. 2023
- [2] Moticon.(n.d.) Opengo: Wireless insole sensor system. Retrieved July 2024, (<https://www.moticon.de/en/opengo>)