

## LSTM-Attention을 이용한 보폭 추정

태민우<sup>0</sup>, 강경훈\*, 최상일\*\*

<sup>0</sup>단국대학교 인공지능융합학과,

(주)솔티드,

\*\*단국대학교 컴퓨터공학과

e-mail: {72220500<sup>0</sup>, choisi\*\*}@dankook.ac.kr, kh.kang@salted.ltd\*

## Stride Length Estimation Using LSTM-Attention

Min-Woo Tae<sup>0</sup>, Kyung-Hoon Kang\*, Sang-Il Choi\*\*

<sup>0</sup>Dept. of AI-based Convergence, Dankook University,

\*Salted Co. Ltd.,

\*\*Dept. of Computer Engineering, Dankook University

### ● 요약 ●

본 논문에서는 3축 가속도와 3축 각속도 센서로 구성된 관성 측정 장치(IMU)와 압력센서가 내장되어있는 스마트 인soles를 착용하여 얻어진 보행 데이터를 통해 보폭을 추정하는 방법을 제안한다. 먼저 압력센서를 활용하여 한 걸음 주기로 나눈 뒤 나누어진 가속도와 각속도 센서 데이터를 LSTM과 Attention 계층을 결합한 딥러닝 모델에 학습하여 보폭 추정을 시행하였다. LSTM-Attention 모델은 기존 LSTM 모델보다 약 1.14%의 성능 향상을 보였다.

**키워드:** 보폭 추정(Stride Length Estimation), LSTM, Attention

### I. Introduction

정상적인 보행을 하기 위해서는 다수의 하지 관절과 근육을 포함한 근골격계 기능뿐만 아니라 전정 기능, 인지 기능과 같은 신경계 관련 기능의 협동이 필요하므로 보행에 관여하는 여러 기능 중 하나라도 문제가 생기면 보행 운동 장애가 일어날 수 있다[1].

따라서 보행 분석을 통해 뇌졸중, 파킨슨병, 당뇨병 족부궤양 등 보행 운동에 영향을 줄 수 있는 질병을 조기에 감지하거나 해당 질병에 대한 치료 이후 신체적인 재활 정도를 판단하는 데 도움을 주는 것이 가능하다.

또한, 인구 고령화 현상으로 인해 2022년 현재 노년층 인구가 전체 인구의 약 17%에 이르렀고, 비교적 근력이나 관절이 약한 노년층을 대상으로 올바른 보행을 할 수 있도록 보조할 수 있는 보행 분석 기술의 필요성이 더욱 대두되고 있다.

### II. Stride Length Estimation Method

#### 1. Data Collection & Preprocessing

3축 가속도와 3축 각속도 센서로 구성된 관성 측정 장치(IMU)와 4개의 압력센서가 내장되어있는 스마트 인soles를 착용하고 트레드밀 위를 보행하여 센서 데이터를 측정하였다.

데이터는 0.01초 단위(100Hz)로 측정되었고, 압력센서를 활용하여 걸음을 주기별로 나눈 뒤, 가속도와 각속도 센서 데이터에 최소최대 정규화를 실시하여 얻어진 총 3784걸음에 대한 데이터를 학습 데이터 80%, 검증 데이터 20%의 비율로 나누어 학습을 수행하였다.

## 2. LSTM-Attention Architecture

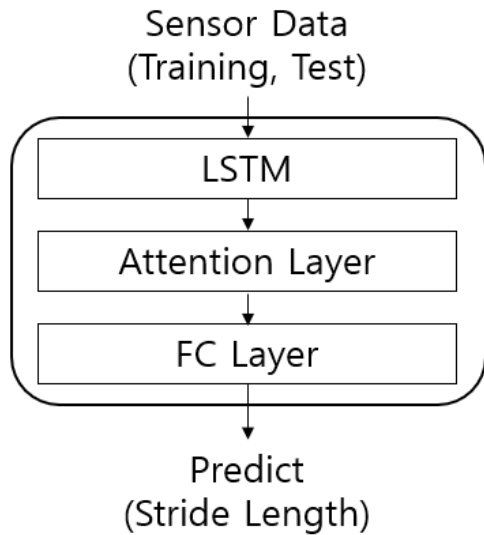


Fig. 1. Architecture Overview

학습 모델은 오래된 입력의 정보 또한 기억할 수 있는 LSTM 모델[2]과 입력 데이터의 어떤 정보가 보폭을 추정하는 과정에 더 중요한 정보를 가지는지 계산하는 Attention 계층[3]을 결합하여 걸음별 특징을 추출하고, 밑단에 추가로 완전연결 계층을 덧붙여 최종적인 보폭을 추정하였다.

완전연결 계층에서의 활성화 함수로 기울기 소실 문제를 해결할 수 있는 ReLU 함수를 사용했으며, 학습률은 0.001, 손실 함수는 평균 제곱 오차(MSE)를 사용하였다.

아울러 20번의 학습 횟수(Epoch) 동안 검증 데이터에 대한 손실 함숫값이 줄어들지 않으면 학습을 종료하는 Early Stopping 기법을 적용하여 과적합을 방지하였다.

## 3. Result

보폭 추정의 평가 지표로 사용한 수식[4]은 다음과 같다.

$$Error(\%) = \frac{1}{N} \sum_{i=1}^N \frac{|S_{pred}^i - S_{target}^i|}{S_{target}^i}$$

$N$ 은 Batch의 크기,  $S_{target}^i$ 은  $i$ 번째 보폭의 실제값,  $S_{pred}^i$ 는  $i$ 번째 보폭의 예측값을 의미한다.

Table 1. Evaluation Result

Model	Error(%)
LSTM	5.36%
LSTM-Attention	4.22%

LSTM은 평가 지표에 따라 실제 보폭과 비교하여 평균 5.36%의 차이를 보였고, LSTM-Attention은 평균 4.22%의 차이를 보여 Attention 계층이 보폭 추정에 있어 기존보다 약 1.14%의 성능 향상을 보였다.

## III. Conclusions

스마트 인술을 통해 얻은 가속도, 각속도 센서 데이터를 LSTM과 Attention 계층을 결합한 네트워크 구조에 입력하여 보폭을 추정하는 방법을 제안하였다. 이후에는 데이터 레이블링이 필요하지 않은 비지도 학습 방법을 적용한 연구를 진행할 예정이다.

## ACKNOWLEDGEMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구결과임. (No. IITP-2022-00155227, 문맥정보를 이용한 딥러닝 기반의 의료 진단에 활용 가능한 ICT-BIO 융합 기술 개발 / No. IITP-2022-0-00899, 멀티 모달 센서가 장착된 스마트 인술을 이용한 보행 패턴 분석 시스템 개발 / No. IITP-2017-0-00 091, 멀티 모달 딥러닝 기반의 바이오 헬스케어 데이터 분석 기술 개발)

## REFERENCES

- [1] 박진세, "보행과 자세불안정의 분석," 대한신경과학회지, 2017; 35(4 suppl): 5-9.
- [2] S.Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, Volume 9, Issue 8, pp.1735-1780, November 1997.
- [3] D. Bahdanau and K. Cho. "Neural Machine Translation by Jointly Learning to Align and Translate," CoRR, abs/1409.0473, 2014.
- [4] Q. Wang, L. Ye, H. Luo, A. Men, F. Zhao, and Y. Huang, "Pedestrian Stride-Length Estimation Based on LSTM and Denoising Autoencoders," Sensors, vol. 19, no. 4, p. 840, 2019.