

# 전이 학습을 통한 GRU와 LSTM의 낙상 검출 성능 향상

김인경<sup>1</sup>, 허성실<sup>1</sup>, 권선영<sup>2</sup>, 이재구<sup>1\*</sup>

<sup>1</sup> 국민대학교 컴퓨터공학과, <sup>2</sup> 클로바 AI Research, 네이버

\*jaekoo@kookmin.ac.kr

## A Fall Detection Performance Improvement using Transfer Learning on GRU and LSTM

InKyung Kim<sup>1</sup>, SeongSil Heo<sup>1</sup>, SunYoung Kwon<sup>2</sup>, JaeKoo Lee<sup>1\*</sup>

<sup>1</sup> Computer Science Department, Kookmin Univ.,

<sup>2</sup> Clova AI Research, Naver Corp.

### 요약

낙상(Fall)은 발생 시 노인 건강에 치명적인 영향을 미칠 수 있기 때문에 낙상을 감지하는 시스템이 필요하다. 그러나 실제 낙상과 ADL(Activity of Daily Living)의 데이터가 부족하기 때문에 모델을 양성하기 어렵다. 이러한 한계를 해소하기 위해, 낙상 감지 모델을 보다 효율적으로 학습하기 위한 전이 학습의 활용을 제안한다. 행동 인식을 위한 시계열 데이터를 분석하기 위해 GRU(Gated Recurrent Unit)와 LSTM(Long Short-Term Memory) 모델 등 순환 신경망(Recurrent Neural Network)을 전이 학습으로 학습했다. 실험 결과 GRU와 LSTM 모델 모두 성능이 우수했으며, 사전 훈련된 모델을 전이 학습을 통해 재학습했을 때 GRU 모델의 학습속도가 LSTM 모델 보다 빨랐다. 또한 GRU 모델은 정밀도, 재현율, f1 점수, 정확도 등이 각각 96%, 98%, 97%, 97%로 모든 면에서 LSTM 모델 보다 우수한 성능을 보였다. 이는 순환신경망을 훈련하기 위해 전이 학습을 사용하지 않은 관련 연구보다 평균적으로 약 3% 나은 결과이다. 이 실험은 전이 학습을 사용하면 낙상 데이터의 부족을 완화할 수 있으며 낙상을 효율적으로 검출 할 수 있는 상대적으로 가벼운 모델인 GRU를 통해 낙상 감지 모델의 개발로 이어질 수 있음을 증명한다.

### 1. 서론

낙상(Fall)은 높은 곳에서 낮은 곳으로 신체의 중심을 잃고 빠르게 움직이는 것을 의미한다. 낙상은 발생 시 노인 건강에 큰 영향을 미칠 수 있기 때문에 조기 발견이 매우 중요하다[1]. 기존 연구들의 다수는 카메라를 통해 수집한 영상이나 사진 데이터를 활용하여 낙상을 검출하였다[2][3]. 하지만 카메라를 활용한 낙상 검출은 초기 설치비용이 비싸고 낙상 검출 공간을 실내로 제한하는 한계를 가진다. 웨어러블(Wearable) 기반의 센서 데이터를 사용한 연구들의 경우, 데이터 양이 적어 훈련이 제대로 이뤄지지 않았다. 또한 낙상은 실시간 감지가 중요한데 이전 연구들은 비교적 연산량이 많은 LSTM을 사용하여 검출을 시도하였다[4]. 그래서 본 논문에서는 가격이 상대적으로 저렴하고 원격지에서도 검출이 가능한 웨어러블(Wearable) 기기 기반의 센서 데이터를 활용하였다. 또한 전이 학습(Transfer Learning)을 사용한 재훈련과 상대적으로 연산량이 적은 GRU(Gated Recurrent)를 사용한 낙상 검출 방법을 제안한다. 실험 결과, 전이학습의 유무에 따라 정밀도(Precision), 재현율(Recall), f1 점수, 정확도(Accuracy)를 비교하였을 때 평균 5% 차이로 전이 학습을 적용하였을 때 성능이 더 뛰어났다. 또한 GRU의 수렴 속도가 LSTM에 비해 약 2.4배 빨랐으며 LSTM에 비해 평균 0.2%정도 성능이 더 우수했다.

### II. 본론

본 논문에서는 두 개의 공개 데이터 셋을 사용하여 실험을 진행하였다. 전반적인 실험 과정은 [그림 1]과 같다. 먼저 SmartFall 데이터 셋을 활용하여 GRU와 LSTM을 학습하였고 학습한 모델을 MobiAct 데이터 셋에 전이

학습하여 GRU와 LSTM 모델의 재훈련을 진행하였다.

데이터 전처리하는 다음과 같이 진행하였다. SmartFall 데이터 셋의 낙상 데이터 샘플은 모두 25개로 동일하게 설정되어있었다. 낙상의 특징을 심층 학습 모델이 학습하기 위해서는 입력 데이터 안에 낙상이 발생하는 과정과 낙상이 발생한 후의 과정이 모두 포함되어야 한다. 이를 위해서 SmartFall 데이터의 낙상이 발생하기 전 상황과 발생한 후의 상황을 모두 포함할 수 있도록 윈도우(Window) 크기를 40으로 설정하였다. 윈도우를 데이터 샘플마다 이동하면서 낙상 데이터인 25개 샘플이 모두 포함되는 경우 '낙상'으로 라벨(Label) 값을 설정하고 25개 낙상 샘플을 모두 포함하지 않는 경우는 'ADL(Activity of Daily Living)'로 라벨 값을 설정하였다. SmartFall 데이터와 구조를 유사하게 맞추기 위해서 MobiAct 데이터의 낙상 데이터를 30개 샘플로 푸리에 방법(Fourier Method)을 사용하여 재샘플링(Resampling)하였다. 재샘플링한 구간의 양쪽에 10개의 ADL 샘플을 추가하여 총 50개의 샘플을 하나의 데이터로 구성하였다. 이후 SmartFall과 동일한 크기의 윈도우로 데이터 샘플을 하나씩 이동하면서 30개의 데이터 낙상 데이터 샘플을 모두 포함할 경우에만 '낙상'으로 설정하였다. ADL의 경우 기존의 MobiAct ADL 데이터를 사용하여 윈도우 크기를 40으로 설정하여 데이터를 추출하였다.

SmartFall 데이터를 사용해서 GRU와 LSTM을 학습한 결과, 정밀도, 재현율, F1 점수, 정확도 등 모든 성능의 측면에서 LSTM이 GRU보다 더 우세했다. 학습 속도는 GRU가 상대적으로 더 적게 소모되었다. 전이 학습을 적용하여 MobiAct 데이터를 재훈련한 결과, SmartFall 데이터로 학습한 모델을 MobiAct 데이터에서 테스트한 결과보다 LSTM의 경우 평균 61%,

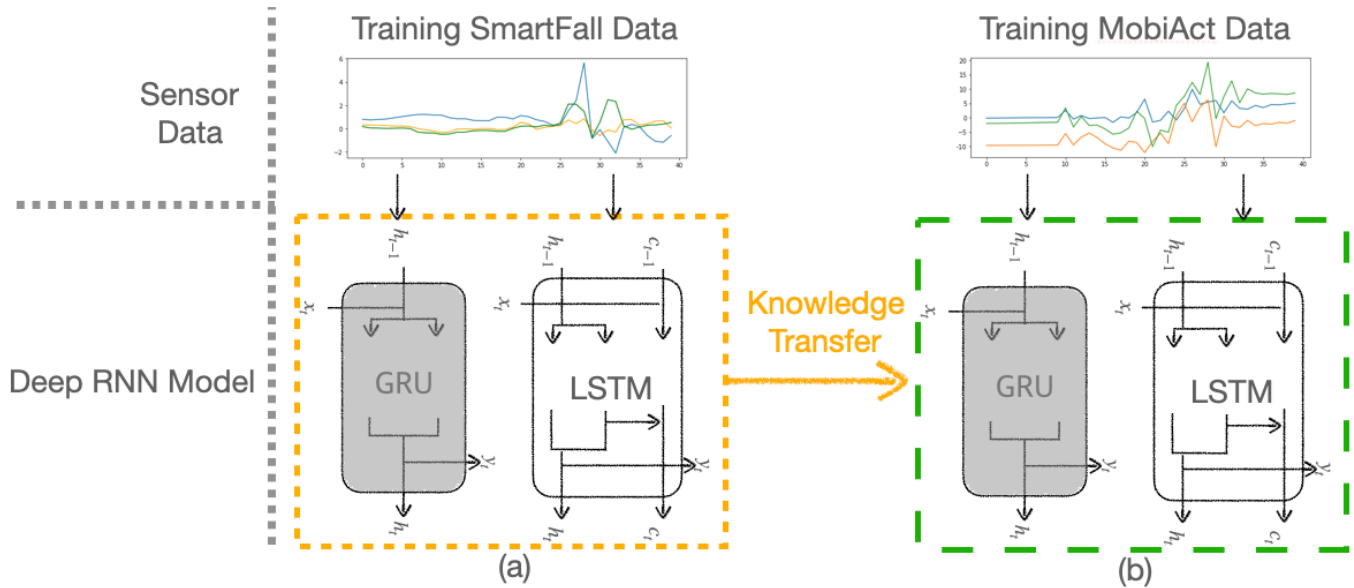


그림 1. 실험의 전반적인 구조, (a) - SmartFall 데이터를 사용하여 GRU와 LSTM을 학습, (b) - 학습된 모델을 MobiAct 데이터에 적용하여 재학습 진행  
GRU의 경우 평균 34% 더 높았다.

MobiAct 데이터를 사용하여 전이 학습한 결과 GRU가 LSTM에 비해 약 2.4배 빠르게 학습하였다.

본 실험을 통해 낙상 데이터 부족으로 나타났던 이전 연구들의 한계점을 전이 학습을 통해 개선할 수 있음을 보여주었다. 또한 LSTM보다 상대적으로 가벼운 모델인 GRU를 사용하여 낙상을 빠르고 정확하게 검출할 수 있다는 것을 증명하였다.

표 1. 전이학습시 LSTM과 GRU 성능 비교

훈련을 진행한 데이터 셋		SmartFall	SmartFall	SmartFall → MobiAct
테스트를 진행한 데이터 셋		SmartFall	MobiAct	MobiAct
LSTM	Precision Score	<b>0.9963</b>	0.4917	0.9570
	Recall Score	0.8411	0.1782	<b>0.9777</b>
	F1 Score	0.9121	0.2616	<b>0.9673</b>
	Accuracy	0.9189	0.4969	<b>0.9670</b>
GRU	Precision Score	<b>0.9963</b>	0.8290	0.9590
	Recall Score	0.8442	0.4371	<b>0.9810</b>
	F1 Score	0.9139	0.5724	<b>0.9699</b>
	Accuracy	0.9205	0.6735	<b>0.9696</b>

### III. 결론

본 논문에서는 기존 논문들에서 데이터의 부족으로 인한 한계를 전이 학습을 통해 해결하였다. 낙상을 실시간으로 감지할 수 있는 방법 중 웨어러블 기기를 통해 수집한 센서 데이터를 사용하였다. 먼저 SmartFall 데이터 셋을 활용하여 각 모델을 학습하였고 훈련된 모델을 MobiAct 데이터에 전이 학습하여 재훈련시켰다. 그 결과 LSTM과 GRU 모두 전이 학습을 진행한 후의 정밀도 점수를 제외한 재현율, F1점수, 정확도 등이 약 5% 정도 상승하였다. 또한 LSTM에 비해 GRU가 더 빠르게 높은 정확도에 수

렴하는 것을 함께 확인하였다. 이전의 전이 학습을 사용하지 않은 순환 신경망을 활용한 연구들에 비해 본 실험의 결과가 약 평균 3% 더 우수한 것을 확인하였다[4]. 본 실험을 통해 이전 연구들이 가지고 있던 낙상 데이터 부족을 해결할 수 있는 척도를 제안하며 시간 낙상 감지를 위한 적절한 모델을 무엇인지에 대해 검증하였다.

### ACKNOWLEDGMENT

이 성과는 2020 년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF2018R1C1B5086441).

### 참 고 문 헌

- [1] S.R. Lord, C. Sherrington and J. C. Close, Falls in Older People: Risk Factors and Strategies for Prevention, Cambridge Univ. Press, 2007.
- [2] Sye-Hyun Hwang, "Fall Detection System Using the Open Source Hardware and RGB Camera", The Journal of Korean Int. of Inf. Tech. 2016, 14.4, pp.19-24, Korea, April, 2016.
- [3] SerDaroglu Serkan, "Video Based Fall Down Detection with Deep Learning", Int. of Control, Robotics and Systems, Vol.2018, No.5, pp. 273-274, Korea, May, 2018.
- [4] Francisco Luna-Perejón, "Wearable Fall Detector Using Recurrent Neural Network", SenSors, 19(22), 4885, Nov., 2019
- [5] Sinno Jialin Pan, "A Survey on Transfer Learning", IEEE, Vol22, Issue10, Oct., 2010
- [6] Mauldin, Taylor R, "SmartFall: A smartwatch based fall detection system using deep learning", Sensors, 18(10), 3363, Oct., 2018
- [7] Chatzaki, C., "Human Daily Activity and Fall Recognition Using a Smartphone's Acceleration Sensor", in Proc. Inf. and Commun. Tech. for Ageing Well and e-Health (ICT4AWE 2016), pp. 100-118, July, 2017