

3축 가속 센서의 가공 파라미터를 장단기 메모리에 적용한 낙상감지 시스템 연구

정승수¹ · 김남호² · 유운섭^{1,*}

¹한경대학교 · ²한국폴리텍대학

Study of the Fall Detection System Applying the Parameters Claculated from the 3-axis Acceleration Sensor to Long Short-term Memory

Seung Su Jeong¹ · Nam Ho Kim² · Yun Seop Yu^{1,*}

¹Hankyong National University · ²Korea Polytechnic

E-mail : su14000@hknu.kr

요 약

본 논문에서는 일상생활에서의 고령자에게 나타날 수 있는 낙상상황을 감지할 수 있는 텐서플로우를 이용한 장단기 메모리 기반 낙상감지 시스템에 대하여 소개한다. 낙상감지를 위해서 3축 가속도 센서 데이터를 이용하고, 이를 처리하여 다양한 파라미터화하며 일상생활 패턴 4가지, 낙상상황 패턴 3가지로 분류한다. 파라미터화한 데이터는 정규화 과정을 따르며, 학습이 진행된다. 학습은 Loss값이 0.5 이하가 될 때까지 진행된다. 각각의 파라미터인 θ , SVM (Sum Vector Magnitude), GSVM (gravity-weight SVM)에 대하여 결과를 산출한다. 가장 좋은 결과는 GSVM으로 Sensitivity 98.75%, Specificity 99.68%, Accuracy 99.28%로 가장 좋은 결과를 보였다.

ABSTRACT

In this paper, we introduce a long short-term memory (LSTM)-based fall detection system using TensorFlow that can detect falls occurring in the elderly in daily living. 3-axis accelerometer data are aggregated for fall detection, and then three types of parameter are calculated. 4 types of activity of daily living (ADL) and 3 types of fall situation patterns are classified. The parameterized data applied to LSTM. Learning proceeds until the Loss value becomes 0.5 or less. The results are calculated for each parameter θ , SVM, and GSVM. The best result was GSVM, which showed Sensitivity 98.75%, Specificity 99.68%, and Accuracy 99.28%.

키워드

Tensorflow, Fall detection, The elderly, Long short-term memory(LSTM)

1. 서 론

현재는 한국의 고령화가 심화되고 있고, 늘어나는 고령층 인구와 문제들 중 하나인 무릎관절증을 비롯하여 여러 가지 노인성 질환들로 인한 낙상 문제가 늘어나고 있는 추세이다. 이러한 낙상문제로 인하여 노인들의 불편함을 해결하고자 낙상감지 시스템을 고안하였다. 딥러닝 기술이 발전하는

지금 기존에 3축가속센서 데이터를 다양한 파라미터로 기계학습인 은닉마르코프방법(HMM)에 적용한 것[1]이 있는데, 텐서플로우를 이용한 LSTM을 적용한 연구는 없어서 본 연구가 필요하다. 3축 가속도 센서[2-3]를 이용한 낙상감지 시스템에 더불어 데이터 패턴을 학습할 수 있는 LSTM (long short-term memory)에 기반한 딥러닝을 이용한 낙상감지시스템을 제시한다.

본 논문은 3축 가속도 센서를 이용하여 측정된 데이터를 파라미터화한 데이터를 LSTM을 이용한

* corresponding author

여 학습하여 파라미터별 정확도에 대하여 기술한다. II장은 LSTM 기반의 낙상감지시스템에 대해서 간략히 설명한다. III장은 학습된 낙상검출 결과를 비교하고, IV장에서 결론을 제시한다.

II. 낙상감지 시스템 요약

데이터는 고령자 몸에 부착되어 있는 3축 가속도 센서에서 실시간으로 벡터값을 출력하여, 이를 파라미터화하고, 분류된 각도(θ), SVM (Sum Vector Magnitude), GSVM (gravity-weight SVM)[1]을 이용하여 LSTM에 적용하여 학습을 진행한다. 이때 정규화 과정을 거치며 최적의 정규화인 최대최소 데이터 정규화 과정[4]과, L2 손실함수 정규화[5]를 적용한다. 각각 데이터 정규화는 Norm=127, 손실함수 정규화는 $\lambda=0.0001$ 을 적용한다. 7가지의 행동 패턴(4가지 일상생활: wlaiking, lying, running, jumping, 3가지 낙상: fall forward, fall sideways, fall backward)이 조사되었다.

III. 결과 비교

실험에는 6명의 건강한 지원자에 의해 이루어졌으며, 4명의 남성과 2명의 여성으로 이루어져 있다. 나이는 20~50대, 키는 160cm~180cm 이며, 몸무게는 50kg~85kg으로 이루어져 있다. 낙상실험에는 20cm의 두께의 매트리스를 사용하였다. 실험데이터는 20대의 남성2명과 20대의 여성2명의 7개의 패턴에 대하여 각각 15개씩 총 420개, 나머지 40대, 50대 남성 2명의 각각의 패턴에 대하여 10개씩 총 140개의 데이터를 사용하였다.

그림1은 LSTM에 의해 학습된 θ , SVM, GSVM에 대해서 7가지 패턴의 검출 정확도의 시각화를 보여준다. GSVM이 가장 검출율이 높음을 보인다.




그림 1. 7가지 패턴 정확도에 대한 시각화. (a) θ , (b) SVM, (c) GSVM

표1과 표2는 각각 θ , SVM, GSVM의 confusion matrix과 sensitivity, specificity, accuracy를 결과를 나타낸다. 학습은 Loss값이 0.5 이하가 될 때까지 진행되어서, 학습횟수는 각각 $\theta = 3579200$, SVM = 864600, GSVM = 540000 이다. 3가지 파라미터 중에서 GSVM이 가장 적은 훈련횟수로도 sensitivity 98.75%, specificity 99.68%, accuracy

99.28%로 가장 좋은 결과를 보여주었다.

표 1. SVM, θ , GSVM의 confusion matrix

parameter	TP	TN	FP	FN
θ	239	309	11	1
SVM	231	313	7	9
GSVM	237	319	1	3

표 2. θ , SVM, GSVM의 sensitivity, specificity, accuracy

parameter	Sensitivity [%]	Specificity [%]	Accuracy [%]
θ	99.58	96.56	97.85
SVM	96.25	97.8	97.14
GSVM	98.75	99.68	99.28

IV. 결 론

고령자의 몸에 부착된 3축 가속도 센서를 이용한 데이터를 처리한 파라미터 데이터를 이용하여 LSTM에 적용하였다. 데이터는 정규화과정을 따르며, 데이터 정규화는 127, 손실함수 정규화는 0.0001을 따른다. 이전의 결과와는 달리 이번실험에서의 결과값은 Loss값을 조정함에 따라 학습의 깊이를 깊게 하게 되어 많은 학습에 따른 결과를 보게 되었다. 3가지 파라미터 중에서 GSVM이 가장 적은 훈련횟수로도 sensitivity 98.75%, specificity 99.68%, accuracy 99.28%로 가장 좋은 결과를 보여주었다. 다양한 파라미터 조합하면 더 나은 정확도를 기대해 볼 수 있다.

Acknowledgement

This research was supported by the Basic Science Research Program through NRF of Korea funded by the Ministry of Education (NRF-2019R1F1A1060383)

References

[1] D. H. Lim and C. H. Park, N. H. Kim "Fall-Detection Algorithm Using 3-Axis Acceleration: Combination with Simple Threshold and Hidden Markov Model" *Journal of Applied Mathematics*, vol. 2014, ID. 896030, pp. 1-8, Feb, 2014.

[2] S. Khojasteh, J. Villar, C. Chira, V. González, and E. de la Cal, "Improving Fall Detection Using an

- On-Wrist Wearable Accelerometer,” *Sensors*, vol. 18, no. 5, p. 1350, Apr. 2018. DOI: 10.3390/s18051350.
- [3] S. Khojasteh, J. Villar, C. Chira, V. González, and E. de la Cal, “Improving Fall Detection Using an On-Wrist Wearable Accelerometer,” *Sensors*, vol. 18, no. 5, p. 1350, Apr. 2018. DOI: 10.3390/s18051350.
- [4] T. Hayashi, S. Watanabe, T. Toda, T. Hori, J. L. Roux, K. Takeda, “Duration-Controlled LSTM for Polyphonic Sound Event Detection,” *IEEE/ACM Trans. Audio Speech Lang. Process.*, vol. 25, no. 11, pp. 2059-2070, 2017. DOI: 10.1109/taslp.2017.2740002.
- [5] T. Van Laarhoven, “L2 regularization versus batch and weight normalization,” 2017. arXiv preprint arXiv:1706.05350.