

기계학습 기반의 낙상 검출

김인경, 김대희, 허성실, 이재구*
 국민대학교 컴퓨터공학과
 *jaekoo@kookmin.ac.kr

Machine Learning based Fall Detection

InKyung Kim, DaeHee Kim, Seongsil Heo, JaeKoo Lee*
 Dept. of Computer Science, Kookmin University

요 약

노인인구의 급증에 따라 노인 건강에 대한 관심이 증가하였고 노인 낙상을 발견하는 방법에 대한 관심도 함께 대두되기 시작하였다. 낙상 사고의 경우 낙상을 일으킨 원인보다 낙상이 제때 감지되지 않아 발생하는 이후의 상황이 더욱 심각한 결과를 초래한다. 따라서 낙상이 발생했을 때, 바로 낙상을 감지할 수 있는 시스템 구축이 필요하다. 다양한 낙상 검출을 위한 방법이 존재하지만 그 중 착용이 쉽고 원거리에서 관찰 및 관리가 가능한 웨어러블(Wearable) 기기의 센서 데이터를 사용한 낙상 검출을 진행하였다. 본 논문에서는 머신 러닝 모델들을 사용해서 낙상 검출 성능 비교 및 적절한 모델을 제안한다. 기계 학습 기반의 모델인 결정 트리(Decision Tree), 랜덤 포레스트(Random Forest), SVM(Support Vector Machine)을 사용하여 실제 측정된 데이터에 낙상 검출 학습 능력을 정량화하였다. 또한, 모델의 입력 값에 적용한 데이터 분할, 전처리 및 특징 추출 방법을 통해서 효율적인 낙상 검출을 위한 기계학습 관점에서의 타당성을 판단하고자 한다.

1. 서론

일반적으로 낙상(Fall)은 높은 곳에서 낮은 곳으로 신체의 중심을 잃고 빠르게 움직이는 것을 의미한다. 반면 ADL(Activity of Daily Living)은 사람들이 일상 생활에서 수행하는 자기 관리를 포함한 모든 활동을 의미하며, 걷기, 식사 하기 등이 이에 해당한다. 현재까지 많은 낙상 검출 연구들은 낙상과 ADL 을 구별하는 방식으로 진행되고 있다[1].

노인인구가 증가함에 따라 낙상에 대한 관심도 함께 증가하는 추세이다. 2018 년 통계청 자료에 따르면, 2018 년 65 세 이상 인구는 738 만 1 천명으로 전체 인구의 14.3%를 차지한다. 2018 년 노년부양비는 19.6 명에서 저출산과 고령화의 영향으로 2060 년에는 82.6 명으로 증가할 전망이다[2]. 2017 년 보건복지부에서 진행한 노인실태조사에 따르면 노인의 15.9%는 낙상 경험이 있으며, 지난 1 년간 낙상 횟수는 평균 2.1 회이다[3]. 낙상으로 인한 주요 손상 부위는 남녀 모두 고관절골절이 가장 많은 것으로 나타난다. 고관절골절은 골절 자체의 문제보다 동반되는 합병증으로 인해 생명까지 위협받을 수 있다.

이렇듯 낙상은 노인들의 건강에 매우 큰 영향을 미칠 수 있기 때문에 낙상이 일어난 순간에 조기 발견이 매우 중요하다. 이를 위해서는 노인들의 행동과

신체적 균형을 지속적으로 관찰해야 한다. 이러한 방법 중 하나가 웨어러블 기기 안에 포함된 가속도계나 자이로스코프 센서를 사용하여 낙상을 검출하는 것이다. 센서를 통해서 기기 사용자가 움직이는 x, y, z 축에 대한 가속도 신호와 방위각을 계산하여 사용자의 움직임을 파악한다.

본 논문에서는 웨어러블 기기의 센서를 통해 수집한 데이터를 대표적인 기계 학습 모델인 결정 트리, 랜덤 포레스트, SVM 을 통해 낙상 검출 성능을 측정하였다. 또한 기계학습 모델에 적용하기 위한 낙상 검출에 특화된 데이터 분할, 전처리 및 특징 추출 방법에 대해서도 함께 논한다.

2. 관련 연구

국내에서 진행된 연구들 중 기계 학습이나 심층 학습(Deep Learning)을 사용한 관련 연구의 다수는 웨어러블 기기와 같은 센서를 통해 추출한 센서 데이터 기반이 아닌 카메라를 통해 얻은 영상을 분석해서 낙상을 검출하고 예측하였다[4][5][6][7]. 이 외에도 낙상 이후 발생하는 실내 바닥의 진동을 측정, 분석하여 낙상의 유무를 판단한 연구도 존재한다[8]. 센서 데이터만 이용한 연구도 존재하지만 기계 학습이나 심층 학습을 사용한 경우가 아닌 단순 임계점을 기준으로

낙상과 ADL 을 구분한 연구가 대다수였다[9]. 기존 카메라를 통해 영상을 분석한 연구와 바닥의 진동을 이용한 연구는 낙상 검출 공간이 실내로 제한되며 검출 기기를 모두 실내에 설치해야 한다는 제한점을 갖는다. 임계점을 통해 낙상을 검출하는 연구의 경우, 사람이 경험적으로 임계점 값을 설정하고 이를 기준으로 낙상을 검출하는 것이기 때문에 신호 자체에 대한 규칙 분석이나 특징 추출이 부재하다. 이는 낙상의 규칙을 통한 검출이 아니기 때문에 일반화된 검출을 유도할 수 없다. 따라서 영상이나 진동을 이용한 방법보다는 웨어러블 기기를 통해 추출한 센서데이터를 사용하는 방법이 좀더 대중적으로 낙상을 검출하는데 도움이 될 수 있으며, 본 연구는 기계 학습 기반의 낙상 검출에 대한 포괄적인 이해를 전달하고자 한다.

3. 실험 환경

3.1 데이터 설명

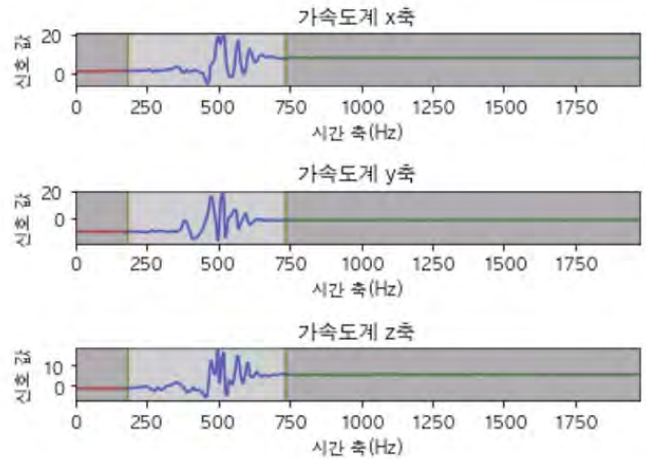
본 실험에서는 공개 데이터인 **MobiFall Dataset** 을 사용하였다[10]. **MobiFall** 데이터는 삼성 갤럭시 S3 스마트 폰을 이용하여 수집되었고 낙상과 ADL 의 가속도계 신호와 자이로스코프 신호를 포함한다. 가속도계의 평균 샘플링 주파수는 87Hz 이고 자이로스코프의 평균 샘플링 주파수는 200Hz 이다. ADL 의 경우 19 명의 참가자들은 11 가지의 ADL 을 시행하였고, 59 명의 참가자는 9 가지의 ADL 을 실행하였다. FALL 의 경우 66 명의 참가자들이 4 가지의 낙상을 실행하였다. 수집된 데이터는 상황에 대한 라벨 값을 모두 포함하고 있다. 아래의 <표 1>은 ADL, 낙상 대한 데이터 라벨 종류를 나타낸 것이다.

	라벨	활동 명	횟수	실행시간(s)
ADL	STD	서있기	1	300
	WAL	걷기	1	300
	SIT	의자에 앉아있기	1	60
	JOG	조깅하기	3	30
	JUM	점프하기	3	30
	STU	계단 오르기	6	10
	STN	계단 내려가기	6	10
	SCH	서있다가 앉기	6	6
	CHU	앉아있다가 서기	6	6
	CSI	차에 타기	6	6
CSO	차에서 내리기	6	6	
FALL	FOL	앞으로 넘어지기	3	10
	FKL	무릎 닿고 넘어지기	3	10
	BSC	뒤로 의자에 앉으면서 넘어지기	3	10
	SDL	옆으로 넘어지기	3	10

<표 1> ADL 과 FALL 데이터 종류

실험에는 **MobiFall** 데이터에 포함된 가속도계 센서 신호만을 이용하였다. 낙상이 발생하는 상황에서의

가속도계 신호 데이터를 시각화한 결과는 아래 (그림 1)과 같다. (그림 1)의 분할된 영역은 각각 순서대로 ‘STD(서있기)’, ‘FALL(낙상)’, ‘LYI(누워있기)’를 의미한다. 각각의 값에는 각각의 값들이 어떠한 상황인지를 알려주는 꼬리표가 포함되어 있다.




(그림 1) 낙상 가속도계 데이터 예시

낙상의 특징을 추출하기 위해서는 낙상이 일어나기 전 상황과 낙상이 발생한 후의 상황을 모두 포함해서 전처리를 진행해야 한다. 이를 위해서 ‘FALL’로 레이블 되어있던 부분을 기준으로 앞 뒤로 1 초 간격의 STD 와 LYI 가 포함되도록 수정하였다. 그 다음으로 a 모든 데이터 샘플의 길이를 최대 길이에 맞추어서 재 샘플링(Resampling)하였다. 이후 평균 이동 필터(Average Filter)를 사용하여 신호의 잡음을 제거하였다. 사용한 평균 이동 필터는 M=2 인 다음의 식을 이용하였다.

$$Y[i] = \frac{1}{M} \sum_{j=-\frac{M-1}{2}}^{\frac{M-1}{2}} X[i+j] \quad (1)$$

3.2 데이터 분할

이전 연구들[11][12]은 낙상이 일어나는 시점부터 낙상이 발생한 후까지의 시간을 모두 포함하는 적절한 시간 간격이 약 2 초라고 판단하였다. 실험에서는 데이터를 분할하는 한 윈도우가 141 개의 값을 포함하도록 설정하였다. 즉, 한 윈도우 당 약 2 초를 포함할 수 있도록 하였다.



(그림 2) 데이터 분할 표시

3.3 특징 추출

특징 추출에 사용된 입력 값 벡터는 다음과 같다.

- 1) (a_x, a_y, a_z) 는 각각 가속도계 신호 데이터의 x, y, z 축 데이터를 의미한다. 즉, 3 개의 축에 대해 각각 141 개의 샘플을 포함하는 $Y(1, \dots, 3, 1, \dots, 141)$ 로 표현할 수 있다.
- 2) A 는 x, y, z 축에 대한 삼차원 가속도를 의미한다. 각 축 벡터의 크기를 사용해서 계산하며 계산식은 아래와 같다.

$$A(1 \dots 141) = \frac{\sqrt{Y(1, 1, \dots, 141)^2 + Y(2, 1, \dots, 141)^2 + Y(3, 1, \dots, 141)^2}}{2} \quad (2)$$

- 3) AV 는 벡터 A 의 각도 변화를 의미한다. AV 를 통해서 몸이 변화하는 각도를 계산할 수 있기 때문에 자이로스코프와 같은 다른 센서 데이터를 추가적으로 사용하지 않았다. AV 의 경우 141 차원의 벡터로 표현이 되어 모든 축(a_x, a_y, a_z)에 대해서 계산한다. n 은 1 부터 141 까지이며 이 값들을 통해 변화하는 a_x, a_y, a_z 에 대한 각도를 구할 수 있다.

$$AV = \left[\cos^{-1} \left(\frac{y^n \cdot y^{n+1}}{\|y^n\| \|y^{n+1}\|} \right) \right] \frac{180}{\pi} \quad (3)$$

결과적으로 (a_x, a_y, a_z, A, AV) 는 특징을 추출하기 위해 사용한 벡터이다. 해당 5 가지 벡터를 x 라고 칭할 때, 추출된 통계적 혹은 신호적 특징들은 다음과 같다.

- 1) 평균(Average): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 평균 값을 계산하였다.
- 2) 최대값(Maximum): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 최대 값 계산하였다.
- 3) 최소값(Minimum): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 최소 값 계산하였다.
- 4) 에너지(Energy): 이산 신호의 에너지는 다음의 방법으로 계산하였다.

$$E = \sum_{i=1}^n |x[n]|^2 \quad (4)$$

- 5) 스펙트럴 에너지(Spectral Energy): 이산 신호의 푸리에 변환을 사용하여 스펙트럴 에너지 값을 계산하였다.

$$E = \sum_{i=1}^n |FFT(x)|^2 \quad (5)$$

- 6) 표준편차(Standard Deviation): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 표준 편차를 계산하였다.
- 7) 상관도(Correlation): 가속도계 벡터 사이의 상관도를 계산하였다. 즉 $(a_x, a_y), (a_x, a_z), (a_y, a_z)$ 사이의 상관도를 측정하였다. 이를 위한 수식은 다음과 같다.

$$corr(x, y) = \frac{E((X - \mu_x)(Y - \mu_y))}{\sigma_x \sigma_y} \quad (6)$$

제시된 방법들을 통해서 총 33 개의 특징을 추출하였고 이를 데이터에 적용하였다.

4. 실험

기계 학습 모델로는 결정 트리, 랜덤 포레스트, SVM 을 사용하였다. MobiFall 데이터의 FALL 데이터 비율은 ADL 데이터 비율보다 훨씬 작다. 그리하여 각각의 모델에 큰 데이터 수에 맞춰 임의의 복원 추출한 훈련 데이터와 작은 데이터 수에 맞춰 임의의 복원 추출한 훈련 데이터를 사용하여 학습을 진행하였다. 실험 데이터의 경우 작은 데이터 수에 맞춰 임의의 복원 추출하였다. 아래의 <표 2>는 진행한 실험의 결과이다.

	F1 점수	정밀도	재현율	정확도
결정 트리				
작은 데이터에 맞춰 임의의 복원 추출	0.77	0.76	0.78	0.77
큰 데이터에 맞춰 임의의 복원 추출	0.77	0.79	0.76	0.78
랜덤 포레스트				
작은 데이터에 맞춰 임의의 복원 추출	0.83	0.79	0.88	0.82
큰 데이터에 맞춰 임의의 복원 추출	0.85	0.86	0.83	0.85
SVM				
작은 데이터에 맞춰 임의의 복원 추출	0.85	0.80	0.90	0.84
큰 데이터에 맞춰 임의의 복원 추출	0.86	0.82	0.90	0.85


<표 2> 기계학습 모델 별 결과

<표 2>에서 볼 수 있듯이 SVM 이 가장 좋은 성능을 보이는 것을 확인할 수 있다. 정밀도(Precision)와 재현율(Recall)의 경우 상충 관계(Trade-Off)에 있기 때문에 하나의 점수가 높으면 상대적으로 다른 점수가

낮은 경향을 함께 보여주고 있다. 또한 전반적으로 작은 데이터에 맞춰 임의 복원 추출한 결과보다 큰 데이터 수에 맞춰 임의 복원 추출한 실험의 성능이 더 좋은 경향을 보인다.

낙상 검출에서는 정확도(Accuracy) 점수만큼 정밀도와 재현율의 점수가 적절하게 함께 높아야 한다. 정밀도 점수는 잘못된 알람(False Alarm)의 여부를 알려주기 때문에 중요하다. 다른 연구들에서도 정밀도와 재현율을 함께 참고할 수 있는 F1 점수를 함께 사용한다. 실험에서는 SVM 의 F1 점수가 0.86 으로 가장 높았다.

본 연구를 통해 전통적인 기계 학습 기반의 낙상 검출의 타당성을 확인하였으며 향후 연구로 깊은 인공 신경망 모델인 CNN(Convolutional Neural Network)과 RNN(Recurrent Neural Network)을 이용하여 낙상 검출을 진행할 예정이며 예상되는 모델은 아래의 (그림 3)과 같다.



(그림 3) 1D CNN 예시

5. 결론

본 논문에서는 다양한 낙상 검출 방법들 중 초기 설치 비용이 상대적으로 저렴하고 실내외에서도 낙상을 바로 검출할 수 있는 웨어러블 기기를 사용하여 기계 학습 기반의 낙상 검출을 실험하였다. 이를 위해 데이터 분할 및 전처리를 진행하였고 모델 학습에 이용하는 전반적인 낙상 검출에 대해서 정량적으로 검증하였다. 대표적인 기계 학습 모델인 결정 트리, 랜덤 포레스트, SVM 등을 적용하였으며 SVM 의 낙상 검출 성능이 다른 모델에 비해 가장 높음을 확인할 수 있었다. 본 연구 결과를 기반으로 최신 깊은 인공 신경망을 적용하여 낙상 검출 성능을 향상시킬 계획이다.

사사

이 성과는 2020 년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원과 과학기술정보통신부 및 정보통신기획 평가원의 SW 중심대학지원사업으로 수행된 연구임 (No. NRF2018R1C1B5086441)

참고문헌

- [1] YACCHIREMA, Diana, et al, 'Fall detection system for elderly people using IoT and big data', Procedia computer science, 130: 603-610, 2018.
- [2] 통계청. '2018 고령자 통계'. https://kostat.go.kr/portal/korea/kor_nw/3/index.board?bmode=read&aSeq=370781&pageNo=&rowNum=10&amSeq=&sTarget=&sTxt=
- [3] 보건복지부, '2017 노인실태 조사', 2017
- [4] 황세현, 반성범, '오픈소스 하드웨어와 RGB 카메라를 이용한 낙상 검출 시스템', 한국정보기술학회 논문지, 14.4: 19-24, 2016
- [5] Serdaroglu Werkan, 박장식, '딥러닝을 이용한 영상기반 사람 쓰러짐 검출', 제어로봇시스템학회, Vol.2018 No.5, 273-274, 2018
- [6] 김대연, 전봉규, '열화상 카메라를 이용한 3D 컨볼루션 신경망 기반 낙상 인식', 로봣학회 논문지, 13(1), pp. 45-54, 2018
- [7] 김선기, 안중수, '영상처리 기반 낙상 알고리즘의 구현', 한국위성정보통신학회논문지, Vol 12 Issue2, p. 56-60, 2017
- [8] 김동완, 유종현, 백승화, '바닥 진동을 통한 노인 낙상 검출', 전기전자학회논문지, 18.1: 134-139, 2014
- [9] 안순재, 김종만, '공개데이터셋을 이용한 충격 전 낙상 검출 알고리즘 평가 및 비교', 한국재활복지 공학회, 192-193, 2018
- [10] VAVOULAS, George, et al, 'The mobifall dataset: Fall detection and classification with a smartphone, In: Artificial intelligence: Concepts, methodologies, tools, and applications, IGI Global, p. 1218-1231, 2017
- [11] GIBSON, Ryan M., et al, 'Multiple comparator classifier framework for accelerometer-based fall detection and diagnostic', Applied Soft Computing, 39: 94-103, 2016.
- [12] Banos, O., Galvez, J. M., Damas, M., Pomares, H., & Rojas, I. 'Window size impact in human activity recognition', Sensors, 14(4), 6474-6499, 2014