

## IMU 원신호 기반의 기계학습을 통한 충격전 낙상방향 분류

이현빈<sup>1</sup> · 이창준<sup>1</sup> · 이정근<sup>2,+</sup>

### Classification of Fall Direction Before Impact Using Machine Learning Based on IMU Raw Signals

Hyeon Bin Lee<sup>1</sup>, Chang June Lee<sup>1</sup>, and Jung Keun Lee<sup>2,+</sup>

#### Abstract

As the elderly population gradually increases, the risk of fatal fall accidents among the elderly is increasing. One way to cope with a fall accident is to determine the fall direction before impact using a wearable inertial measurement unit (IMU). In this context, a previous study proposed a method of classifying fall directions using a support vector machine with sensor velocity, acceleration, and tilt angle as input parameters. However, in this method, the IMU signals are processed through several processes, including a Kalman filter and the integration of acceleration, which involves a large amount of computation and error factors. Therefore, this paper proposes a machine learning-based method that classifies the fall direction before impact using IMU raw signals rather than processed data. In this study, we investigated the effects of the following two factors on the classification performance: (1) the usage of processed/raw signals and (2) the selection of machine learning techniques. First, as a result of comparing the processed/raw signals, the difference in sensitivities between the two methods was within 5%, indicating an equivalent level of classification performance. Second, as a result of comparing six machine learning techniques, K-nearest neighbor and naive Bayes exhibited excellent performance with a sensitivity of 86.0% and 84.1%, respectively.

**Keywords:** Fall direction, Inertial measurement units, Raw signals, Machine learning, Fall detection before impact

#### 1. 서 론

한국 사회는 2017년에 노인 인구가 14.2%를 차지하는 고령 사회에 진입하였으며, 2021년 통계청에 따르면 2025년에 노인 인구가 20%인 초고령사회로 진입할 것으로 전망되고 있다. 이와 같이 노인인구가 증가함에 따라서 다양한 문제들이 발생하게 되는데, 그 중 하나로는 낙상 사고가 있다. 낙상은 신체 부위에 직접적인 충격을 가함으로써 골절과 같은 부상을 일으키며, 이에 따른 후유증 또한 유발하여 일상생활에 영향을 끼치기

때문에, 노인들에게 심각한 문제로 대두되고 있다[1-3].

이러한 낙상 사고의 피해를 최소화하기 위해 다양한 기술들이 개발되고 있으며, 가장 대표적인 방법은 신체에 착용된 관성 측정장치(inertial measurement units, 이하 IMU)를 통해 낙상을 감지하는 것이다[4-7]. IMU는 원격 감지 가능한 소형 경량의 동작 센서로, 일상생활에서도 신체 활동을 실시간으로 모니터링할 수 있어, 낙상과 같은 상황을 감지하는 데에 유용하게 활용된다. 대표적인 예시로, IMU가 내장된 스마트 워치를 통해 낙상 사고를 감지하고 대처한 사례를 쉽게 볼 수 있다[8,9].

현재 활용되는 많은 낙상감지 기술은 착용자가 이미 쓰러지고 난 후에 수행되는 방식으로, 이후에 움직임이 감지되지 않으면 응급 서비스에 착용자의 위치와 상태를 알리는 등의 대응이 이뤄진다. 다만, 이는 충격 후 낙상을 감지하는 방식이기 때문에, 충격에 의한 신체적 손상 및 정신적 피해의 유발은 불가피하다. 이에 따라서 낙상의 충격 피해를 최소화하기 위해 인플레이터블 에어백(inflatable airbag)과 같은 충격완화 시스템이 개발되고 있으며[10-12], 이를 구현하기 위해서는 충격 전에 미리 낙상을 감지하고 어느 방향으로 넘어지는지를 판별하는 기술이 요구된다[13-15]. 이는 넘어지는 방향에 따라서 충격을 받고

<sup>1</sup> 한경대학교 기계공학과(Mechanical Engineering, Hankyong National University)

327 Jungang-ro, Anseong, Gyeonggi 456-749, Korea.

<sup>2</sup> 한경대학교 ICT 로봇기계공학부 (School of ICT, Robotics & Mechanical Engineering, Hankyong National University)

327 Jungang-ro, Anseong, Gyeonggi 456-749, Korea.

<sup>+</sup>Corresponding author: jklee@hknu.ac.kr

(Received: Jan. 18, 2022, Revised: Mar. 17, 2022, Accepted: Mar. 18, 2022)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<https://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

손상될 수 있는 신체 부위를 파악하고, 충격완화 시스템이 해당 부위를 보호할 수 있도록 작동되어야 하기 때문이다.

Lee[16]는 기계학습(machine learning) 기법 중 하나인 서포트 벡터 머신(support vector machine, 이하 SVM)을 통해 충격 전 낙상방향을 분류하는 방법을 제안한 바 있다. 여기서 낙상방향을 분류하기 위한 입력 파라미터로는 센서의 기울기 각도(tilt)와 속도 및 가속도가 적용되었으며, 이 중 속도를 사용한 경우가 가장 우수한 분류 성능을 나타냈다. 다만 IMU는 이러한 물리량들을 직접적으로 제공하지 않기 때문에, 이를 추정하기 위한 신호처리 과정이 요구된다. 기울기 각도의 경우, 칼만필터(Kalman filter) 내에서 IMU 신호를 결합함으로써 추정된 기울기 자세로부터 추출되며[17], 센서 가속도는 기울기 자세를 사용하여 가속도계 신호에 중력 가속도 성분을 제거함으로써 얻어진다. 또한 센서의 속도는 위의 과정을 통해 얻어진 센서 가속도를 시간에 대해 적분함으로써 추정 가능하다. 이러한 과정은 복잡하고 많은 양의 계산을 필요로 한다.

본 논문은 충격전 낙상방향 감지를 대상으로 하므로 낙상에 대한 대응이 짧은 시간 내에 신속하게 이루어져야 한다는 제약과, 실용용시에는 일반적으로 소형 저가의 내장 프로세서가 IMU 신호 처리를 위해 이용된다는 점을 고려한다면, 낙상방향 감지를 위해 단순한 신호처리가 요구된다. 무엇보다 Lee[16]의 방법은 속도계산을 위한 적분과정에서의 오차 누적이 발생할 수 있으며, 이 경우 낙상방향 감지의 성능에도 영향을 미칠 수 있다는 문제점을 지닌다.

이에 본 논문에서는 기존의 복잡한 가공 과정을 거치기보다, IMU의 원신호(raw signal)를 그대로 사용하여 충격 전 낙상방향을 분류하는 방법을 시도한다. 우선, 가공 과정의 유무에 따른 분류 성능의 변화를 확인하기 위하여, 제안방법을 가공된 데이터를 사용하는 기존 연구의 방법과 함께 비교하였다. 또한 제안방법에서 여러 기계학습 기법(SVM 외 5가지)을 적용하여, 그에 따른 분류 성능을 비교하였다.

## 2. 방법 및 시험 데이터

### 2.1 낙상방향 분류 방법

본 연구에서는 낙상방향을 분류하기 위해 3축 가속도계와 3축 자이로스코프로 구성된 6축 IMU를 활용한다. 이 중, 가속도계는 중력가속도를 포함한 선형 가속도를, 그리고 자이로스코프는 회전 각속도를 측정하며, 두 센서의 3축 신호는 각각  $y_A = [y_{A,x} \ y_{A,y} \ y_{A,z}]$  와  $y_G = [y_{G,x} \ y_{G,y} \ y_{G,z}]$  로 표현된다. 여기서 X축은 전진 방향을, Y축은 좌측 방향을, 그리고 Z축은 윗방향을 나타낸다(Fig. 1 참조). 이때, 이전연구[16]에서 높은 성능을 보인 센서의 부착 위치는 허리이므로, 본 연구에서는 허리에 부착한 센서를 사용한다.




Fig. 1. Fall directions and a waist-attached IMU

낙상방향 분류 문제는 크게 전/후 또는 좌/우를 분류하는 이진 분류와 전/후/좌/우, 이 4가지 방향을 분류하는 다중 분류로 나누어 접근 가능하다. 이러한 낙상방향을 분류에 있어서 적절한 축 방향의 파라미터를 사용하는 것이 중요하다. 예로, 이전 연구에서는 전후방 분류를 위해 X축의 속도(또는 가속도)와 Y축의 각도(피치)를 사용하였으며, 좌우측 분류를 하는 데에 Y축의 속도와 X축의 각도(롤)를 사용하였다. 이때, 속도와 기울기 각도는 각각 가속도계 및 자이로스코프의 신호와 연관된다. 예로, X와 Y 축의 속도는 가속도계의 각 축 신호 ( $y_{A,x}$ ,  $y_{A,y}$ )와 연관되고, X와 Y축의 회전 각도(롤, 피치)는 자이로스코프의 각 축 신호( $y_{G,x}$ ,  $y_{G,y}$ )와 연관된다. 이에 이진 분류에서는 분류하고자 하는 낙상방향과 연관된 축 방향의 신호를, 다중분류에서는 두 가지의 축 방향 신호를 모두 사용한다. Fig. 2와 3은 각각 네 가지 방향의 낙상에서 나타나는 가속도계와 자이로스코프 신호를 보여준다. 예로 전/후 방향의 경우, 가속도계 신호는 X축(파랑) 성분, 자이로스코프 신호는 Y축(주황) 성분과 연관되어 있음을 알 수 있다.

본 방법에서는 낙상방향을 분류하기 위하여, 센서의 원신호를 바탕으로 간단한 특징 파라미터를 추출하여, 기계학습의 입력 파라미터로 사용한다. 특징 파라미터로는 낙상으로 감지된 시점을 기준으로 그 이전의 특정시간 동안 측정된 센서 신호의 최대값(max), 총합(sum), 그리고 평균값(mean)이 적용되었다. 본 논문에서 특정시간은 0.3초로 설정하였다.

낙상방향을 분류하기 위한 기계학습 기법으로, 기존 연구에서 사용된 SVM과 함께 다음의 다섯가지 기법이 적용되었다: K-최근접 이웃(K-nearest neighbor, 이하 KNN), 의사결정 나무(decision tree, 이하 DT), 선형 판별 분석(linear discriminant analysis, 이하 LDA), 나이브 베이즈(naive bayes, 이하 NB), 신경망(neural networks, 이하 NN). 상기 기법들은 주로 분류 문제에 활용되는 지도학습 형식의 기계학습 기법에 해당하며, 모두 MATLAB에서 제공하는 함수들을 통해 학습 및 분류가 이뤄졌다.

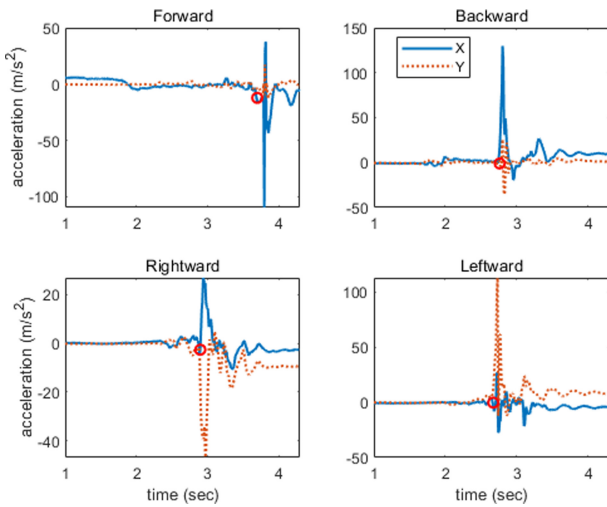


Fig. 2. Accelerometer signals for each fall direction.




Fig. 3. Gyroscope signals for each fall direction.

## 2.2 시험 데이터 및 분석

본 연구에서 낙상방향의 분류 및 성능 평가를 위하여, 이전 연구[16]의 낙상 시험 데이터를 활용하였다. 시험은 건강한 성인 남성 11명을 대상으로 시행되었으며, 피험자마다 4가지 방향(전방, 후방, 좌측면, 우측면)의 낙상을 3가지 유형으로 2번씩 반복하여 수행되었다. 각 낙상 시험의 유형에 관한 설명은 참고문헌[16]에 자세히 명시되어 있다.

해당 시험에서는 가속도계와 자이로스코프가 내장된 MTw IMU(Xsens Technologies B. V., Netherlands)가 사용되었으며, 센서는 벨크로 밴드를 이용하여 배꼽아래 부근 허리에 부착되었다. 센서 신호는 100 Hz의 샘플링률로 측정되었다. 시험 데이터는 각 피험자에 대해 총 24개(4가지 방향 × 3가지 시험유형 × 2번의 시행)로 구성되며, 총 264개의 데이터가 활용되었다. 또

한 제안방법에서 특징 파라미터를 추출하는 데에 필요한 낙상 감지 시점으로는, [16]에서 수직속도 기반의 감지 기법[7]을 통하여 낙상으로 판별한 시점의 시간을 사용하였다.

기계학습의 분류 성능은 학습 및 검증 데이터의 선정에 따라 달라지므로, 데이터 선정에 따른 판별결과의 영향성을 최소화하기 위해 이분할 교차검증(two-fold cross validation)이 적용되었다. 피험자 11명의 데이터를 5명과 6명으로 나누어서 첫번째는 전자와 후자를 학습 및 검증 데이터로, 그 다음에는 후자와 전자를 바꾸어 적용하였다. 분류 성능은 이전 연구의 성능 지표와 동일하게 민감도(sensitivity)를 통해 검증되었다.

본 연구에서는 다음의 두 가지에 대하여 비교 분석하고자 한다: 첫째는 가공과정을 포함하는 이전 연구[16]의 방법과 IMU 원신호를 사용하는 제안방법 간의 분류 성능 비교, 그리고 두번째는 제안방법에서 기계학습 기법에 따른 분류성능 비교.

첫번째로 비교되는 대상인 이전 연구의 방법에서는 센서의 속도, 가속도, 그리고 틸트각을 입력 파라미터로 사용하여, SVM을 통해 낙상방향을 분류한다. 위의 세 가지 파라미터들 중, 속도와 틸트각을 사용한 경우가 성능이 우수하였기 때문에, 이 두 가지를 입력 파라미터로 사용한다. 두번째로 기계학습 기법 별 성능 비교에서는 2.1절에서 설명된 여섯 가지의 기계학습 기법을 사용하고 이에 따른 분류 성능을 비교 분석한다.

## 3. 낙상 방향 분류 결과

### 3.1 가공과정 유무에 따른 분류성능 비교

이번 절에서는 가공된 데이터를 사용하는 기존 연구의 방법(Conv.)과 IMU의 원신호를 사용하는 제안방법의 분류 성능을 비교 분석한다. 이때, 제안방법에서는 3가지 특징 파라미터(max, sum, mean)를 적용하였으며, 기계학습 기법으로는 [16]의 방법과 동일하게 SVM을 적용하였다.

Table 1은 전후방 및 좌우측에 대한 이전 분류의 성능 결과를 보여준다. 우선, 모든 파라미터에 대하여 비교하였을 때, 가공 데이터 중 하나인 속도를 사용한 경우의 민감도가 모든 방향에 대해서 100%로, 가장 우수한 분류 성능을 보여주었다. 또한 기울기 각도를 사용한 경우에는 전/후에 대해 80% 이상, 좌/우에 대해 90% 이상의 민감도를 나타냈다. IMU의 원신호를 사용하는 제안방법에서는 대체로 자이로스코프 신호를 사용한 경우가 가속도계에 비해 우수한 분류 성능을 보였다. 또한 특징별로 비교하였을 때, sum과 mean을 사용한 경우의 성능이 우수하였다. 이 두 가지의 특징 파라미터는 대부분의 결과에서 동등한 성능을 보였지만,  $y_{G,y}$ 를 사용하여 전후방을 분류하였을 때에는, mean의 성능이 더 우세한 것을 확인하였다. 자이로스코프 신호의 mean을 사용하는 제안방법과 속도를 사용하는 기존방법의 성능을 비교하였을 때, 좌/우에 대해

**Table 1.** Sensitivities (%) of binary classification: comparison of results from processed/raw signals.

	Forward vs. Backward			Rightward vs. Leftward		
	Input	F	B	Input	R	L
Conv.	$v_x$	100	100	$v_y$	100	100
	<i>pitch</i>	83.4	87.9	<i>roll</i>	96.9	90.9
max	$y_{A,x}$	87.5	71.4	$y_{A,y}$	95.8	94.2
	$y_{G,y}$	94.2	93.9	$y_{G,x}$	98.6	100.0
sum	$y_{A,x}$	91.1	90.3	$y_{A,y}$	95.6	96.9
	$y_{G,y}$	95.8	90.6	$y_{G,x}$	100.0	100.0
mean	$y_{A,x}$	91.1	90.3	$y_{A,y}$	95.6	96.9
	$y_{G,y}$	95.8	95.6	$y_{G,x}$	100.0	100.0

**Table 2.** Sensitivities (%) of multi-classification: comparison of results from processed/raw signals.

	Input	F	B	R	L	Avg.
Conv.	$v_x$ & $v_y$	93.8	91.3	62.3	63.6	77.8
	<i>pitch</i> & <i>roll</i>	77.0	74.2	43.2	56.2	62.7
max	$y_{A,x}$ & $y_{A,y}$	0.0	53.1	0.0	95.0	37.0
	$y_{G,x}$ & $y_{G,y}$	73.1	60.8	75.8	85.8	73.9
sum	$y_{A,x}$ & $y_{A,y}$	56.9	45.0	65.8	81.7	62.4
	$y_{G,x}$ & $y_{G,y}$	51.1	26.7	45.0	38.3	40.3
mean	$y_{A,x}$ & $y_{A,y}$	58.3	45.0	65.8	81.7	62.7
	$y_{G,x}$ & $y_{G,y}$	83.6	54.4	79.7	88.3	76.5

**Table 3.** Sensitivities (%) of binary classification: comparison according to the selection of machine learning techniques.

	$y_{G,y}$		$y_{A,x}$		$y_{G,y}$ & $y_{A,x}$		$y_{G,x}$		$y_{A,y}$		$y_{G,x}$ & $y_{A,y}$	
	F	B	F	B	F	B	R	L	R	L	R	L
SVM	95.8	95.6	91.1	90.3	94.2	93.9	100.0	100.0	95.6	96.9	100.0	100.0
KNN	91.1	94.2	86.9	82.2	91.1	94.2	100.0	100.0	95.3	93.9	100.0	100.0
DT	92.8	96.9	86.4	90.8	92.8	95.3	100.0	100.0	100.0	93.9	100.0	100.0
LDA	94.2	95.6	91.4	90.3	94.2	97.2	100.0	100.0	95.6	96.9	100.0	100.0
NB	94.2	92.8	92.8	88.6	94.2	95.6	100.0	100.0	95.6	96.9	100.0	98.3
NN	94.2	97.2	91.1	81.9	94.2	94.2	100.0	100.0	96.7	95.3	100.0	100.0

서는 모두 동일하게 100%, 전/후에 대해서는 제안방법이 비교적 낮은 민감도를 보였지만, 그 차이는 5% 이내로 동등한 수준의 성능이 확인되었다.

Table 2는 전/후/좌/우, 4가지 방향을 분류하는 다중 분류의 성능 결과를 보여준다. 파라미터 별로 분류 성능을 비교하였을 때, 이진분류의 경우와 마찬가지로 속도가 가장 우수한 분류 성능을 보였다(평균 77.8%). 제안방법에서는 특징 또는 센서 신호에 따라서 분류 성능이 매우 상이하게 나타나는 모습이 확인되었는데, 그 중 자이로스코프 신호에 mean과 max를 적용하였을 때의 민감도가 각각 76.5와 73.9%로, 속도를 사용한 경우에 비해서 약간은 낮지만 거의 동등한 수준의 성능을 나타냈다. 이를 통해 IMU의 원신호를 사용하여 낙상방향을 분류하였을 때, 동등한 수준으로 분류할 수 있음을 확인하였다.

### 3.2 기계학습 기법별 분류성능 비교

3.1절에서는 가공된 데이터(속도 및 기울기 각도)를 사용하는 경우와 IMU의 원신호를 사용하는 경우의 분류 성능을 비교하고 있다. 3.1절의 결과는 모두 SVM을 적용한 결과이나, 기계학습 기법도 분류 성능에 영향을 미치는 요인 중 하나이기 때문에, 이에 따른 영향 또한 확인될 필요가 있다. 따라서 이번 절에서는 기계학습 기법에 따른 분류 성능을 비교한다. 이때 특징으로는 3.1절에서 가장 높은 성능을 보인 mean을 적용하였으며, IMU의 두 센서 신호를 조합하여 사용한 경우를 추가적으로 확인하였다.

Table 3은 제안방법의 기계학습 기법별 이진 분류의 성능 결과를 보여준다. 우선, 모든 기법에 대하여 입력 파라미터 별로

**Table 4.** Sensitivities (%) of multi-classification: comparison according to the selection of machine learning techniques.

	<i>gyro</i> (= $y_{G,x}$ & $y_{G,y}$ )					<i>acc</i> (= $y_{A,x}$ & $y_{A,y}$ )					<i>gyro</i> & <i>acc</i>				
	F	B	R	L	Avg.	F	B	R	L	Avg.	F	B	R	L	Avg.
SVM	83.6	54.4	79.7	88.3	76.5	58.3	45.0	65.8	81.7	62.7	82.5	59.2	78.9	80.0	75.1
KNN	89.7	75.8	95.8	85.8	86.8	75.6	67.5	73.9	62.8	69.9	89.7	75.8	95.8	82.8	86.0
DT	81.9	75.0	87.2	82.5	81.7	69.2	68.1	76.9	70.3	71.1	79.7	78.6	61.1	54.4	68.5
LDA	77.5	54.7	71.7	86.7	72.6	58.6	43.9	65.8	82.8	62.8	79.7	50.8	76.9	90.0	74.4
NB	83.6	68.3	86.1	92.2	82.6	65.0	54.4	74.2	89.7	70.8	84.4	71.1	89.7	91.1	84.1
NN	85.8	55.6	88.1	92.2	80.4	71.1	70.6	68.6	73.1	70.8	47.2	64.2	86.1	83.9	70.3

분류 성능을 비교하였을 때, 3.1절의 결과와 마찬가지로, IMU의 두 센서 중 자이로스코프 신호를 사용한 경우의 성능이 더 우수하였으며, 특히 좌/우에 대해서는 모두 100%의 민감도를 나타냈다. 또한, 두 센서 신호를 조합한 경우에는 자이로스코프 신호를 사용한 경우와 거의 동등한 수준의 분류 성능을 나타냈다. 기계학습 기법별로 비교하였을 때, 기법에 따라서 민감도가 상이하게 나타났지만, 그 차이는 매우 크지 않은 것으로 확인되었다. 예로, 전/후 분류를 위해 가속도계 신호를 사용한 경우에서 기법별 민감도의 편차가 가장 큰 수준으로 나타났지만, 최대 편차는 5.45%에 불과하였다. 또한, 좌/우 분류를 위해 자이로스코프 신호를 사용하는 경우에는 모든 기법이 동일하게 100%의 민감도를 보였다. 즉, 이진 분류에서는 기계학습 기법보다 입력 파라미터의 선정이 분류 성능에 더 큰 영향을 끼치는 것을 알 수 있다.

Table 4는 기계학습 기법별 다중 분류의 성능 결과를 보여준다. 우선 입력 파라미터로는, 가속도계(*acc*)보다 자이로스코프(*gyro*) 신호를 사용한 경우의 성능이 더 우수하였다. 또한, 두 센서 신호를 조합한 경우(*gyro* & *acc*)는 대부분의 모델에서 자이로스코프 신호만을 사용한 경우와 동등한 성능을 보였지만, DT와 NN에서는 오히려 민감도가 크게 저하되는 모습을 보였다. 즉, IMU의 두 센서 신호를 사용하기보다 자이로스코프 신호만을 사용하였을 때, 더 높은 분류 성능을 얻을 수 있음을 확인하였다. 또한 기계학습 기법별 성능을 비교하였을 때, 이진 분류에 비해서 기법 간의 성능 차이가 두드러졌으며, 자이로스코프 신호를 사용한 경우, KNN, NB, DT, NN, SVM, LDA 순으로 민감도가 높았다. 두 센서를 조합한 경우에도 여섯 가지의 기법 중에서 KNN과 NB, 이 두 가지 기법이 높은 수준의 민감도를 나타냈다(KNN: 86.0%, NB: 84.1%). 이를 통해 이진 분류보다 다중 분류에서 기계학습 기법의 선정이 분류 성능에 큰 영향을 끼친다는 것을 알 수 있으며, KNN과 NB를 적용하였을 때, 비교적 높은 성능으로 낙상방향을 분류할 수 있음을 확인하였다.

#### 4. 고찰 및 결론

본 논문에서는 IMU의 원신호를 사용하여 충격전 낙상방향을

분류하는 기계학습 기반의 방법을 제안하였으며, 크게 두 가지 측면에 대한 결과를 확인하였다: (1) 낙상방향 분류를 위한 입력 파라미터로 IMU 신호로부터 가공 과정을 거친 데이터를 사용하는 경우와 센서의 원신호를 사용하는 경우의 분류 성능 비교, (2) 기계학습 기법의 선정에 따른 분류 성능 비교. 두 가지 모두 이진분류와 다중분류로 나누어 결과를 확인하였다.

1. 가공된 데이터로는 속도를, 그리고 센서의 원신호로는 자이로스코프 신호에 *mean*을 적용한 경우가 이진/다중분류에서 모두 우수한 성능을 보였다. 또한 이 두 가지 경우를 비교하였을 때, 속도를 사용하는 기존 방법의 민감도가 좀 더 높았지만, 그 차이는 매우 크지 않았다.

2. 이진 분류에서는, 기계학습 기법의 선정에 따른 영향이 입력 파라미터의 영향에 비해서 크지 않았던 반면에, 다중 분류에서는 기계학습 기법의 영향이 비교적 큰 것으로 확인되었다. 또한 여섯 가지 기계학습 기법의 성능을 비교한 결과, KNN과 그 다음으로는 NB를 사용하였을 때의 분류 성능이 우수하였음을 확인하였다.

첫번째의 결과에서는 제안방법의 분류 성능이 기존 방법에 비해 약간 떨어진다는 것이 확인되었으나, 제안방법은 가공된 데이터를 사용하는 기존 방법과 다르게, 가공과정을 거치지 않는 IMU의 원신호를 사용하였다는 점에서 그 의미가 크다. 기존 논문[16]의 방법에서는 기울기 자세 정보를 추정하기 위한 칼만필터와, 속도를 추정하기 위한 가속도의 적분 등 많은 양의 계산을 수반하는 신호처리 과정을 거치게 된다. 서론에서 언급되었듯이, 낙상에 대한 대응은 신속하게 이뤄져야 하지만, 이러한 가공 과정들은 시간의 지연을 유발하는, 즉, 낙상의 대응에 있어서 바람직하지 않은 요인에 해당한다. 또한 실용용시 장시간동안 신호처리가 이뤄져야 하지만, 가속도의 적분 과정은 시간에 따른 오차 누적에 취약하며, 이는 결과적으로 분류 성능에 악영향을 끼친다. 반면에 제안방법은 센서의 원신호를 사용하기 때문에, 계산량 문제나 시간의 영향과는 무관하다는 이점을 지닌다. 이에 따라서 제안방법이 보다 효율성이 높을 것으로 판단된다.

추가적으로, SVM 외의 다양한 기계학습 기법을 적용함으로써 보다 더 높은 분류 성능을 얻을 수 있음을 확인하였다. 다만, 본 논문에서는 센서 신호나 특정 파라미터를 다양한 방식으로

조합하기보다, 각각의 센서 신호에(또는 두 가지 센서 신호에) 한가지의 특징만을 적용하였다. 이에 따라서 본 논문에서 적용되지 않은 또다른 방식의 입력 파라미터를 적용함으로써, 분류 성능을 보다 향상시킬 수 있을 것으로 예상된다.

단, 본 연구에서는 충격전 낙상을 감지하는 데에 IMU 신호로부터 추정된 수직속도가 이용되었다는 점에서, 센서 신호의 가공과정이 완전히 배제되었다고 보기는 어렵다. 그럼에도, 본 연구의 핵심은 낙상방향을 분류함에 있어 IMU의 원신호를 사용하였다는 점에 있으며, 추후에는 충격전 낙상 감지 또한 센서의 원신호에 기반한 기법으로 충분히 대체 가능할 것으로 기대된다.

### 감사의 글

본 연구는 2018년도 정부(교육부)의 재원으로 한국연구재단 기초연구사업(No. 2018R1D1A1B07042791)의 지원을 받아 수행됨.

### REFERENCES

- [1] K. S. Kang and J. Yang, "A study on the fear of falling, activity of daily living and quality of life for the elderly", *J. Acad.-Ind. Coop. Soc.*, Vol. 18, No. 7, pp. 193-199, 2017.
- [2] D. Evans, J. Pester, L. Vera, D. Jeanmonod, and R. Jeanmonod, "Elderly fall patients triaged to the trauma bay: age, injury patterns, and mortality risk", *Am. J. Emerg. Med.*, Vol. 33, No. 11, pp. 1635-1638, 2015.
- [3] K. I. Lee and J. H. Lee, "The impacts of daily stress, ego resilience, and quality of life of the elderly in long-term care institutions", *Korea Convergence Society*, Vol. 8, No. 6, pp. 325-336, 2017
- [4] M.N. Nyan, F. E.H. Tay, and E.Murugasu, "A wearable system for pre-impact fall detection", *J. Biomech.*, Vol. 41, No. 16, pp. 3475-3481, 2008.
- [5] T. Prajapati, N. Bhatt, and D. Mistry, "A survey paper on wearable sensors based fall detection", *Int. J. Comput. Appl.*, Vol. 115, No. 13, pp. 15-18, 2015.
- [6] J. K. Lee, S. N. Robinovitch, and E. J. Park, "Inertial sensing-based pre-impact detection of falls involving near-fall scenarios", *IEEE Trans. Neural Syst. Rehabilitation Eng.*, Vol. 23, No. 2, pp. 258-266, 2015.
- [7] J. K. Lee, "Study on vertical velocity-based pre-impact fall detection", *J. Sens. Sci. Technol.*, Vol. 23, No. 4, pp. 251-258, 2014.
- [8] S. Troiler-McKinstry and P. Murali, "Fall detection using commodity smart watch and smart phone", *Int. Conf. Artif. Intell.: Appl. Innov.*, Vol. 436, pp. 70-78, 2014.
- [9] T. R. Mauldin, M. E. Canby, V. Metsis, A. H. H. Ngu, and C. C. Rivera. "SmartFall: A smartwatch-based fall detection system using deep learning", *Sensors*, Vol. 18, No. 10, pp. 3363, 2018.
- [10] G. Shi, C. S. Chan, W. J. Li, K. S. Leung, Y. Zou, and Y. Jin, "Mobile human airbag system for fall protection using MEMS sensors and embedded SVM classifier", *IEEE Sensors J.*, Vol. 9, No. 5, pp. 495-503, 2009.
- [11] T. Tamura, T. Yoshimura, M. Sekine, M. Uchida, and O. Tanaka, "A wearable airbag to prevent fall injuries", *IEEE Trans. Inf Technol Biomed*, Vol. 13, No. 6, pp. 910-914, 2009.
- [12] S. Ahn, D. Choi, J. Kim, S. Kim, Y. Jeong, M. Jo, and Y. Kim, "Optimization of a pre-impact fall detection algorithm and development of hip protection airbag system", *Sens. Mater.*, Vol. 30, No. 8, pp. 1743-1752, 2018.
- [13] A. T. Özdemir and B. Barshan, "Detecting falls with wearable sensors using machine learning techniques", *Sensors*, Vol. 14, No. 6, pp. 10691-10708, 2014.
- [14] M. Ş. Turan and B. Barshan, "in press", "Classification of fall directions via wearable motion sensors", *Digit. Signal Process.*, 2021.
- [15] F. Hossain, M. L. Ali, M. Z. Islam and H. Mustafa, "A direction-sensitive fall detection system using single 3D accelerometer and learning classifier", *Proc. of Int. Conf. Med. Eng. Health Inform. Technol.*, pp. 1-6, 2016.
- [16] J. K. Lee, "Determination of fall direction before impact using support vector machine", *J. Sens. Sci. Technol.*, Vol. 24, No. 1, pp. 47-53, 2015.
- [17] J. K. Lee, E. J. Park, and S. N. Robinovitch, "Estimation of attitude and external acceleration using inertial sensor measurement during various dynamic conditions", *IEEE Trans. Instrum. Meas.*, Vol. 61, No. 8, pp. 2262-2273, 2012.