

베이지안 기반의 근전도 발화 측정을 이용한 낙상의 예측

Bayesian Onset Measure of sEMG for Fall Prediction

박성식¹, 김기훈[†]

Seongsik Park¹, Keehoon Kim[†]

Abstract: Fall detection and prevention technologies play a pivotal role in ensuring the well-being of individuals, particularly those living independently, where falls can result in severe consequences. This paper addresses the challenge of accurate and quick fall detection by proposing a Bayesian probability-based measure applied to surface electromyography (sEMG) signals. The proposed algorithm based on a Bayesian filter that divides the sEMG signal into transient and steady states. The ratio of posterior probabilities, considering the inclusion or exclusion of the transient state, serves as a scale to gauge the dominance of the transient state in the current signal. Experimental results demonstrate that this approach enhances the accuracy and expedites the detection time compared to existing methods. The study suggests broader applications beyond fall detection, anticipating future research in diverse human-robot interface benefiting from the proposed methodology.

Keywords: Fall Prediction, Surface Electromyogram (sEMG), Bayesian Method, Onset Detection

1. 서 론

낙상을 탐지하고 예방하는 기술은 중요한데, 특히 많은 낙상 사고가 혼자 지내는 노약자에서 많이 일어나기 때문에 낙상으로 인해 부상을 당하거나 의식을 잃어 자발적으로 도움을 요청할 수 없는 경우에 더 심각한 결과를 초래한다는 점에서 더욱 중요^[1]하다. 이를 위해 여러 센서를 이용하여 대상자의 낙상을 자동으로 감지하는 여러 기술이 개발되었다. 여기에는 깊이 센서, IMU, 카메라와 같이 동작을 측정할 수 있는 센서들을 사용해 왔으며^[2-4], 최근에는 센서를 단독으로 사용하는 것 외에도 센서를 조합한 멀티 모달 낙상 감지 연구도 이루어지고 있는 추세^[5-7]이다.

만약 낙상을 더 정확하면서도 이른 시간에 감지할 수 있다면, 낙상의 발생을 단순히 자동으로 감지하는 것이 아니라 예측하고 예방하는 시스템에도 적용이 가능할 것이다. 예를 들어 사용자의 보행을 보조하는 로봇 장치가 낙상을 이르게 감지한다면 낙상 자체를 방지하는 작업을 수행할 수 있을 것이다. 낙상 감지에서 표면 근전도(surface electromyogram, sEMG)는

사용이 편리하다는 점 외에도 이른 시점에서 낙상을 감지하거나 심지어 예측할 수 있다는 가능성을 가지고 있다는 점에서 다른 신호들과 차별화될 수 있다. 이는 [Fig. 1]과 같이 표면 근전도가 결국 근육이 활성화될 때 발생하는 활동 전위로부터 발생하기 때문에, 신호가 관찰되는 시점과 근수축이 움직임을 실제로 만들어내는 시점 사이에 EMD (electromechanical delay)라 불리는 시간 차가 존재하기 때문이다. 이러한 시차는 보고된 바에 의하면 수십에서 수백 밀리초(ms)로 알려져 있다^[8-10].


그러나 EMD는 통계적인 결과로만 주로 보고가 이루어졌다. 이는 표면 근전도가 발화하는 정확한 시점을 특정하기가 신호의 특성상 어렵기 때문이다. 즉, 표면 근전도에서 실제 발화로 인한 신호의 변화와 잡음으로 인한 변화를 구분짓는 것이 어렵다. 그렇기 때문에 여러 수행을 누적하여 통계값을 도출하는 방식으로 주로 보고되었으며, 신호가 온라인으로 들어오는 단 한 번의 수행 내에서 현재 신호가 실제 발화로 인해 변화하는 것인지 아니면 잡음으로 인한 변화인지 판단하는 것은 쉽지 않은 일이다.

일반적으로 근전도의 발화를 탐지하기 위해서 사용되는 방법은 기준 잡음(baseline noise)에서 측정된 신호의 표준 편차의 일정 배율 이상의 신호가 탐지되었을 때를 기준으로 삼는 것이다^[11-13]. 또한, 일정 구간 안에서 신호가 부호를 달리하는 횟수를 세는 zero-crossing도 신호의 발화를 구분하는 기준으로

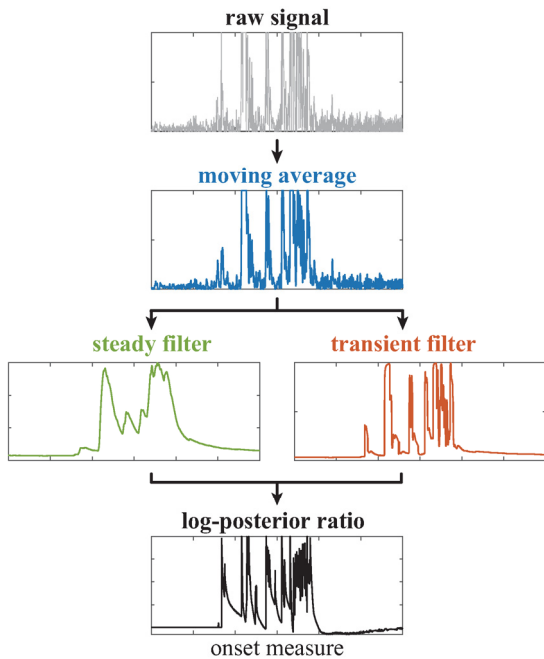
Received : Mar. 26. 2024; Revised : May. 5. 2024; Accepted : May. 7. 2024

1. Assistant Professor, Division of Advanced Engineering, Korea National Open University, Seoul, Korea (spark88@knou.ac.kr)

† Associate Professor, Corresponding author: Department of Mechanical Engineering, POSTECH, Pohang, Korea (khk@postech.ac.kr)



[Fig. 1] The principle of sEMG and the time difference between sEMG and actual movement (electromechanical delay, EMD)



[Fig. 2] The working principle of the posterior probability ratio in measuring the prevalence of the transition state

로 삼기도 한다. 이외에도 에너지 기반의 Teager-Kaiser 방법^[14]이나 profile likelihood maximization^[15] 등의 방법이 제안된 바 있다^[16-21]. 그러나 이러한 방법들이 실제로 기준 잡음으로부터 근전도의 발화만을 충분히 민감하게 탐지해내고, 앞서 언급한 EMD의 활용을 극대화할 수 있는지 평가된 적은 없는 것으로 알려졌다.

낙상이 자발적이지만 정상적이지 않은 근육의 발화에서 일어난다는 가정 하에, 본 논문에서는 근전도가 발화하는 정도 내지는 신호의 비정상성을 측정할 수 있는 Bayesian 확률 기반^[22,23]의 척도를 고안했다. 이 알고리즘이 돌아가는 원리는 비교적 단순하다. 근전도 신호를 전이 상태(transient state)와 정상 상태(steady state)로 나누어서 모델링하는 필터^[22,23]를 사용하되, 전이 상태를 포함한 필터값의 사후 확률(posterior probability)과 전이 상태를 포함하지 않은 필터값의 사후 확률의 비율을 계

[Table 1] Nomenclature

x	hidden signal, filter output
y	observation, measured signal, filter input
ζ	log-likelihood ratio, onset measure
$p(x, t)$	prior probability of x at time t
$p(x y)$	posterior probability of x
$p(y x)$	observation probability of y for a given x
$(\cdot)_t$	a realization of (\cdot) at time t
$(\cdot)_T$	transient filter output
$(\cdot)_S$	steady filter output
α	steady coefficient or diffusion coefficient
β	transient coefficient or drift coefficient

산하여, 현재 신호에 전이 상태가 얼마나 우세하게 나타나고 있는지를 측정할 수 있는 척도로 삼았다. 이러한 원리를 [Fig. 2]에도 나타내고 있다. 이 방법을 사용하여 낙상을 예측하는 경우, 근전도를 이용하는 다른 방법과 비교하였을 때 정확도를 더 높이면서도 동시에 감지하는 시간을 앞당기는 결과를 보여주었다.


본 논문은 다음과 같은 구성으로 이루어져 있다. 먼저 2장에서 제안하는 알고리즘의 방법에 대해서 설명하며 3장에서는 실험 방법, 결과 및 그에 대한 고찰을 다룬다. 마지막으로 4장에서는 결론을 맺으며 논문을 마친다. 모든 논의에 앞서 이 논문에서 일관되게 사용한 변수와 그 표기법에 대해 [Table 1]과 같이 정리하고 시작한다.

2. 방법

이 논문에서 제안하는 방법은 먼저 사후 확률값을 두 개의 서로 상반된 필터의 출력값에 대해 계산한다. 두 필터는 Bayesian 기반의 필터이며 이를 적용하는 절차는 동일하지만, 각 필터의 매개변수를 달리하여 하나의 필터는 정상 상태만으로 다른 하나의 필터는 전이 상태를 포함하도록 하였고 이를 각각 steady 필터와 transient 필터라고 명명하였다. 이 장은 확률 분포 함수의 동적인 전파를 통해 두 필터의 출력값 \hat{x}_{St} 및 \hat{x}_{Tt} 을 구하는 2.1절, 계산된 출력값으로부터 사후 확률을 구하고 그 비율 ζ_t 를 계산하는 2.2절, 그리고 낙상 감지 모델과 그 모델에 들어갈 입력 특성(input feature)을 다루는 2.3절로 구성되어 있다.

2.1 Steady 및 transient 필터

우리의 관측 y 는 절대값을 취한 근전도 신호, 혹은 여기에 이동 평균(moving average, MAV)을 취한 신호이며, 이 관측은



[Fig. 3] Overall algorithm flowchart

숨어있는 정류된 근전도 필터 출력값에 의해 지배되는 것으로 확률적으로 모델링하여 우리는 관측으로부터 숨어있는 정류된 값을 Bayesian 기법을 통해 추정하는 필터라고 볼 수 있다. Bayesian 기법의 모든 절차는 [Fig. 3]에 표현되어 있다.

숨어있는 신호 x 의 사전 확률(prior probability) 분포 함수 $p(x)$ 는 식 (1)과 같이 미분 방정식으로 표현된다. 여기서 $U(x)$ 는 균등 분포(uniform distribution)를 의미한다. 먼저 steady 필터의 확률 분포 함수를 보면 확산 방정식(diffusion equation)에 의해 지배받는 것을 볼 수 있다. 확산 방정식이란 확률 분포 함수의 시간에 따른 변화량이 신호에 대해 두 번 미분한 값에 비례하는 미분 방정식을 의미하는데, 매질에서 확산해나가는 입자-브라운 운동(Brownian motion)을 하는 입자의 위치에 대한 시간에 따른 확률 분포 함수가 지배받는 방정식이기 때문이다. 확산 방정식을 따르는 steady 필터의 확률 분포 함수 $p_S(x,t)$ 는 시간이 경과함에 따라 그 최대 위치는 변하지 않으나 이를 중심으로 점점 더 퍼져가는 양상을 보인다. 이는 정상 상태에서 근전도 신호의 변화를 브라운 운동과 같이 모델링한다는 의미이다. 확산을 나타내는 정상 상태 항은 매개변수 α 로 조절하도록 구성하였다.

반면에 전이 상태를 포함하기 위해서는 신호가 점차적으로 변화하는 것이 아닌 전체 영역 어디로든 신호가 움직일 수 있는 확률 분포가 필요하다. 신호의 전이란 신호가 특정 영역에 머무르는 것이 아니라 어디로든 전이한다는 뜻이기 때문이다. 그렇기 때문에 가장 극단적인 형태의 전이 상태 확률 분포는 균등 분포가 되어야 하며, 식 (1)의 미분 방정식에 추가적인 항 $U(X) - p_T(x,t)$ 을 넣어서 확률 분포 함수를 시간이 변화함에 따라 균등 분포가 되도록 만들어 주었다. 확산 방정식은 비슷한 곳에서 점차 퍼져나가는 정상 상태 변화를 표현하면서 동시에 균등 분포와 같이 거동하게 만드는 전이 상태 변화가 포함된 것이다. 이 전이 상태 항은 steady 필터에는 들어있지 않

으며, transient 필터에만 포함되어 있어야 한다. 이 전이 상태를 나타내는 항에 따른 필터링 출력 값의 변화는 [Fig. 1]에서도 확인이 가능하다. 균등 분포로 만들어주는 전이 상태 항은 매개변수 β 를 이용해 조절하도록 되어있다.

$$\frac{\partial p_S(x,t)}{\partial t} = \alpha \frac{\partial^2 p_S(x,t)}{\partial x^2} \tag{1}$$

$$\frac{\partial p_T(x,t)}{\partial t} = \alpha \frac{\partial^2 p_T(x,t)}{\partial x^2} + \beta \{U(x) - p_T(x,t)\}$$

$$p_S(x,t + \Delta t) \leftarrow p_S(x,t) + \Delta t \frac{\partial p_S(x,t)}{\partial t} \tag{2}$$

$$p_T(x,t + \Delta t) \leftarrow p_T(x,t) + \Delta t \frac{\partial p_T(x,t)}{\partial t}$$

$$p(y | x) = N(y; x, \sigma^2) \tag{3}$$

주어진 숨은 신호 x 에 대한 관측 y 의 확률은 식 (3)과 같이 평균 x 를 중심으로 하는 정규분포로 모델링하였다. 사후 확률 (posterior probability)은 앞서 전파시킨 사전 확률에 현재 관측의 우도 확률을 곱해서 식 (4)와 같이 얻어지며, 이렇게 구해진 사후 확률은 다시 다음 관찰 시점에서의 사전 확률로 식 (5)와 같이 새롭게 갱신되어 들어간다. 이를 통해 사전 확률에 우도 확률을 통해 현재 관측을 반영하여 사후 확률로 변환되는 과정이 이루어진다. 특히 이 과정에서 확률 분포가 퍼지는 확산 과정과 우도 확률을 곱해 확률 분포를 다시 모아주는 과정이 서로 균형을 맞출 수 있도록 매개변수들을 적절히 조절해주어야 한다²³⁾. 현재 시점에서 관측과 더불어 모든 계산을 거친 사후 확률이 주어졌을 때, 이 관측 아래에 숨어 있는 필터 추정값 \hat{x} 는 식 (6)과 같이 MAP (maximum a posteriori estimate) 추정을 적용하였다.

$$p_S(x | y = y_t, t) \propto p(y = y_t | x) p_S(x, t) \tag{4}$$

$$p_T(x | y = y_t, t) \propto p(y = y_t | x) p_T(x, t)$$

$$p_S(x, t) \leftarrow p_S(x | y = y_t, t) \tag{5}$$

$$p_T(x, t) \leftarrow p_T(x | y = y_t, t)$$

$$\hat{x}_{S,t} = \operatorname{argmax}_x p_S(x | y = y_t, t) \tag{6}$$

$$\hat{x}_{T,t} = \operatorname{argmax}_x p_T(x | y = y_t, t)$$

2.2 사후 확률비

확률비 기반의 가설 검증에서는 각 가설 하에서 해당 관측이 일어났을 확률을 계산하여 어떠한 가설이 더 일어날 법한 사건인지를 계속한다. 특히 두 가설 중 하나의 가설을 선택해야 할 때에는 두 가설의 확률 사이의 비율을 통해 특정 비율이

상으로 차이가 나는 경우 하나의 가설을 선택하거나 탈락시키는 결정의 근거로 삼는다.

여기에서도 전이 상태의 포함 여부로 나뉘어지는 서로 상반된 두 가지의 Bayesian 필터를 적용하였고, 각각의 필터로부터 사후 확률을 계산할 수 있다. 이는 식 (7)의 식에서 알 수 있듯이 각각의 사후 확률이 최대가 되는 지점을 우리가 MAP 추정을 통해 결정했기 때문에, 그 위치에서의 사후 확률값을 그대로 가져와 식 (8)과 같이 그 사이의 비율을 측정하게 된다. 이로부터 전이 상태를 포함했을 때가 포함하지 않았을 때에 비해 얼마나 더 관측될 법한 사건인지를 측정할 수 있게 된다. 이를 우리는 현재 신호가 얼마나 전이 상태에 가까운지를 나타내는 척도로 삼고자 한다. 확률비에 log를 취했으므로, 0을 기준으로 양의 방향으로 그 값이 클수록 전이 상태가 강하게 나타나며, 반대로 음의 방향일 경우 전이 상태가 약하고 정상 상태가 더 강하다고 해석할 수 있기 때문이다.


$$\begin{aligned} \max p_S(x | y = y_t, t) &= p_S(x = \hat{x}_{S,t} | y = y_t, t) \\ \max p_T(x | y = y_t, t) &= p_T(x = \hat{x}_{T,t} | y = y_t, t) \end{aligned} \quad (7)$$

$$\begin{aligned} \zeta_t &= \log \frac{p_T(x = \hat{x}_{T,t} | y = y_t, t)}{p_S(x = \hat{x}_{S,t} | y = y_t, t)} \\ &= \log \frac{p(y = y_t | x = \hat{x}_{T,t}) p_T(x = \hat{x}_{T,t}, t)}{p(y = y_t | x = \hat{x}_{S,t}) p_S(x = \hat{x}_{S,t}, t)} \end{aligned} \quad (8)$$

2.3 특징의 구성과 낙상 감지 모델

낙상 감지 모델은 SVM (support vector machine)을 사용하였으며 커널(kernel)로는 RBF (radial basis function)을 이용하였다. 기본적으로 낙상 감지 모델에 [Fig. 4]와 같이 근전도의 필터링된 결과들을 입력으로 넣는데, 총 네 가지 경우로 구분할 수 있으며 이를 [Table 2]와 같이 요약하였다. 우리가 선택할 수 있는 것으로는 근전도의 크기에 대한 필터값, 그리고 사후 확률비의 포함 여부이며 각각 두 가지씩 총 네 가지 경우가 존재한다.

먼저 근전도의 필터값으로 두 가지를 선택할 수 있다. 첫째는 일반적인 이동 평균값 y_t , 다른 하나는 전이 상태를 포함한



[Fig. 4] Feature selection and detection algorithm for fall prediction

[Table 2] Input feature for fall detection model

case	input feature	explanation
1	y_t	moving average (MAV)
2	$\hat{x}_{T,t}$	transient filter output
3	$y \times \zeta_t$	MAV and log-probability ratio
4	$\hat{x}_{T,t} \times \zeta_t$	transient filter output and log-probability ratio

transient 필터의 출력값 $\hat{x}_{T,t}$ 이다. 이 둘을 비교하는 이유는 기본적인 필터링 성능에서 이동 평균은 샘플 수를 늘일수록 평탄화 성능은 더 좋아지지만 반응성이 떨어진다는 단점을 갖는데, 전이 상태를 포함한 필터의 경우 정상 상태나 전이 상태나 모두 대응이 가능하기 때문에 평탄화와 반응성 모두 얻을 수 있다는 점에서 차별화가 되는지 확인하기 위함이다.

여기에 우리가 제안하는 사후 확률비를 통해 계산한 척도를 추가하거나 추가하지 않았을 때의 성능도 함께 비교를 수행한다. 이는 우리가 제안한 사후 확률비가 순수하게 전이 상태의 정도를 계량한 값이라면 이를 포함하여 반응성이나 정확성을 개선하는 효과가 있는지 검증하기 위함이다. 이는 기존의 이동 평균과 같은 정류화 필터에서 기본적으로 평활화되는 민감한 전이 상태 신호까지도 민감하게 예측할 것을 기대할 수 있다.


3. 실험

실험 결과는 크게 3.2절에서 단일한 수행에서의 결과를 자세히 살펴보고 3.3절에서는 여러 반복적인 수행에서 얻어진 통계적 결과를 보여준다.

3.1 실험 설계 및 절차

본 연구는 건강한 성인 남성 3명(25.67 ± 0.47세)을 대상으로 실험을 진행하였으며, 모든 피실험자는 실험에 대한 설명을 듣고 자발적으로 참여하였다. 실험은 포항공과대학교 (Pohang University of Science and Technology, POSTECH)의 생명윤리위원회(institutional review board, IRB)에 의해 승인되었다(승인번호: PIRB-2023-E014).

근전도 신호와 더불어 실제 동작을 측정하기 위한 IMU가 내장되어 있는 Delsys 사의 Trigno Avanti 시스템을 이용하여 신호를 수집하였다. 총 4개의 무선 센서 모듈이 이용되었으며, 각각의 센서 모듈에는 하나의 건식 근전도 센서와 9축의 IMU가 내장되어 있다. 신호의 수집 주기는 근전도가 1259 samples/s, IMU가 148 samples/s로 서로 상이하다. 각각의 센서는 [Fig. 5]와




[Fig. 5] Electrode placement: (1) quadriceps femoris, (2) biceps femoris, (3) medial gastrocnemius and (4) lateral gastrocnemius

같이 오른쪽 다리에 부착하였다.

피실험자는 센서를 착용한 상태로 가만히 서 있다가 본인이 원하는 임의의 시점에 전면으로 자발적으로 넘어지는 방식으로 실험을 진행하였다. 기준이 되는 낙상 시점은 IMU의 자이로스코프와 가속도계 값을 기준으로 매겨진 시점이며, 이때 시간을 0초로 하여 시간의 기준점이 될 수 있도록 하였다.

3.2 단일 수행 결과

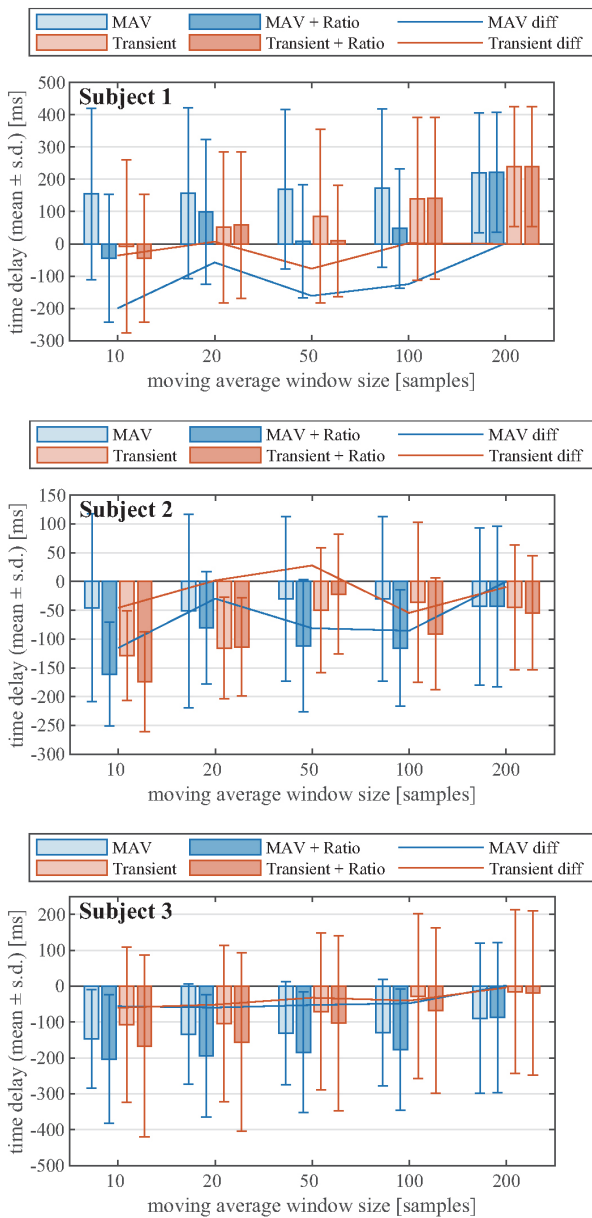
무엇보다 단일 수행에서는 서로 다른 두 필터 사이에 구해진 사후 확률비가 의도한 대로 실제로 동작했는지 확인할 필요가 있다. 센서의 모든 측정값과 알고리즘의 출력값들을 [Fig. 6]에 표현하였다. 특히 모든 결과 그래프에서 수직선으로 IMU를 기준으로 감지한 낙상의 시점을 검은색, 제안한 알고리즘으로 감지한 낙상의 시점을 빨간색으로 표현하였다. 이 두 세로선의 시점 차이가 곧 제안한 알고리즘을 통해 낙상의 감지 시점을 앞당긴 시간으로 볼 수 있을 것이다. 이 근전도로 감지된 낙상 시점(빨간 수직선)을 보면, IMU에서는 아직 어떠한 변화도 관측되지 않고 있는 것을 볼 수 있으며, 근전도에서도 매우 작은 정상 상태 출력만 관측되고 있는 것을 볼 수 있다. 반면 전이 상태를 포함한 경우 찰나에 발생한 큰 신호를 포착하여 정상 상태 필터와 그 결과값을 달리 나타내었으며, 이 차이로 인해 확률비에서도 커다란 피크값이 관측된 것으로 풀이할 수 있다. 특히 전이 상태에 얼마나 가까운지를 나타내는 척도인 확률비값을 보면 신호의 크기가 얼마나 크고 작은지와는 관계 없이 단지 상대적인 전이 상태만을 측정하고 있는 것을 볼 수 있다. 이는 신호의 크기와 무관하게 전이 상태를 일관되게 관측할 수 있음을 보여준다.



[Fig. 6] Sensor measurements in a single trial: from the top (1) sEMG filter (including steady state and transient state filters), (2) probability ratio for onset measurement, (3) gyroscope measurements, and (4) accelerometer measurements. Falls detected through IMU are marked with black vertical lines, and falls detected through sEMG with the proposed method are marked with red vertical lines

3.3 통계적 결과

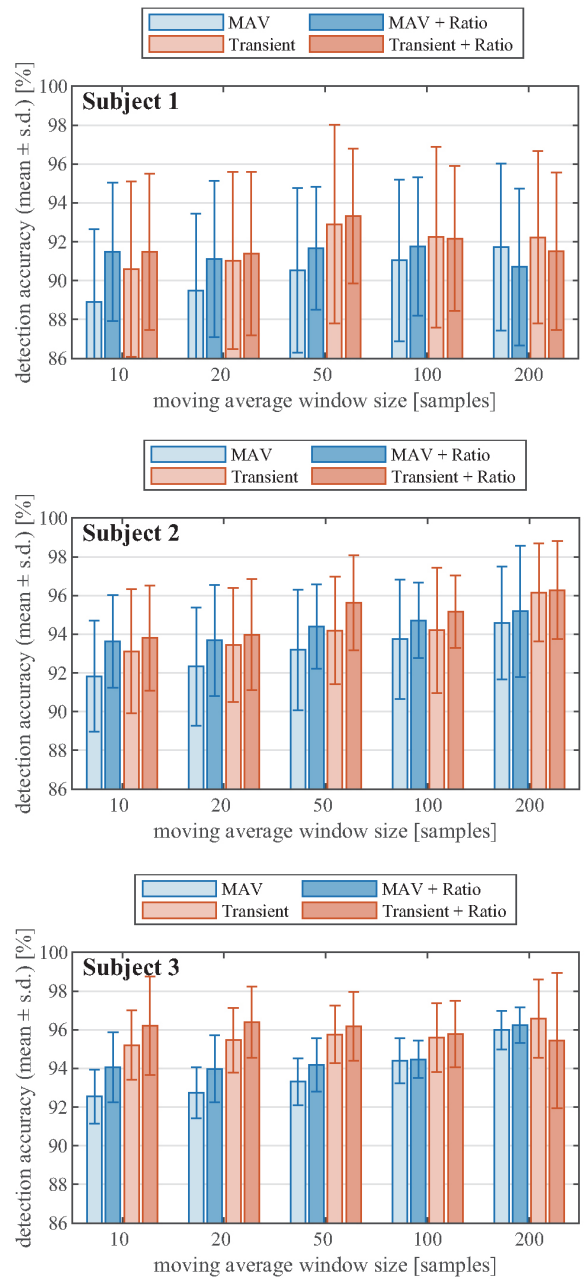
여러 반복적인 수행에서 얻어진 정량적인 값들의 통계적인 경향을 살펴보고자 한다. 우리가 고려하는 시간은 IMU를 이용해서 낙상을 감지한 시점과 제안하는 방법을 이용해서 낙상을 감지했을 때 사이의 시간차이다. 앞선 IMU로 감지된 시간



[Fig. 7] The detection time of falls via sEMG compared to IMU for each subject: a negative value indicates that sEMG detects falls more quickly. The light-colored bar graph represents the results using filters only, while the dark-colored bar graph represents the results when the proposed method is augmented. The line graph indicates the reduced detection time when the proposed method is augmented

을 0초로 고정했기 때문에, 근전도로 감지된 시간이 -100 ms 라면 IMU에 100 ms 앞서서 낙상을 관측했다는 이야기가 된다. 이러한 값들을 [Table 2]와 같이 입력 특성을 달리했을 때 어떤 차이가 나타나는지 관찰하고자 한다.

[Fig. 7]에서 막대고 표현하고 있는 값은 곧 근전도를 기반으로 서로 다른 특성을 선택했을 때 낙상이 탐지된 상대적인



[Fig. 8] Accuracy of fall detection for each subject: the light-colored bar graph represents the accuracy when using filters only, while the dark-colored bar graph represents the accuracy when the proposed method is augmented

시간의 통계적인 분포를 보여주는 것이며, 여기에 직선으로 표현된 것은 각각의 특성-즉 이동 평균(MAV)과 Bayesian 필터 출력값-에 우리가 제안한 확률비(onset measure)를 추가(augmentation)했을 때, 탐지 시간이 얼마만큼 단축되는지를 표현하였다. 여기서 직선이 음수로 나타나는 것도 역시 탐지가 더 빨리 이루어지는 방향으로 정의하였다. 가장 주목할 만한 부분 중 하나는 확률비를 통해 발화 정도를 측정할 값을 낙

상 탐지 모델의 입력으로 추가해서 넣으면, 검출 시간이 모든 경우에서 명확하게 감소한다는 점이다. 이는 모든 경우에서 직선으로 표현한 그래프가 음수 영역에 있다는 점에서 나타난다. 탐지 시간이 줄어든 정도는 피실험자에 따라 약 50 ms에서 200 ms 정도이며, 정확한 값은 각각의 그래프에서 확인이 가능하다. 제안한 방법을 낙상 감지의 특성으로 추가하기 전과 후에 대해 단측 t-검정을 수행했을 때 통계적인 유의미성($p = 1.1425E-05$)이 확인되었다.

[Fig. 8]에서는 동일한 요령으로 낙상 탐지의 정확도를 보여 주고 있다. 정확도는 실제 음성이나 양성을 맞춘 샘플의 수를 전체 샘플의 수로 나누어서 계산하였다. 여기에서도 제안한 발화 정도를 측정할 값을 추가할 때, 모든 경우에서 평균적으로 탐지 정확도가 증가하는 것으로 나타났다. 일반적으로 이 동 평균의 경우 창이 크기가 커질수록 검출되는 시간이 빨라 지지만 정확도는 반대로 감소하는 경향을 보이는데 반해, 우리가 제안한 방법의 경우에는 탐지 시간을 단축하면서 동시에 탐지 정확도도 개선하는 것을 보여주었다. 이는 제안하는 방법이 검출 반응성과 정확성 사이에 존재하는 트레이드-오프(trade-off)를 함께 개선할 수 있는 증거로 해석이 된다.

4. 결 론

이 논문에서 우리는 근전도를 입력으로 사용하여 낙상을 감지하는 시스템을 통해, 다른 센서나 방법에 비해 낙상 감지의 정확도를 유지하거나 개선하면서 동시에 시간을 단축하거나 더 빠르게 예측하는 것을 보여주고자 했다. 우리는 근전도의 발화를 빠르고 정확하게 측정하는 새로운 척도를 제안하였다. 전이 상태와 정상 상태로 구분되어 모델링된 Bayesian 필터를 기반으로, 전이 상태가 포함된 필터와 포함되지 않은 필터를 설계하여 둘 사이의 확률비를 통해 현재 신호가 얼마나 전이 상태에 가까운지를 평가하고자 하였다.

제안하는 발화 척도가 낙상 감지의 개선에 중요한 역할을 하는 것을 실험을 통해 검증할 수 있었다. 실험을 통해 우리가 제안하는 척도가 포함되었을 때와 포함되지 않았을 때 수행한 낙상 감지를 비교함으로써 발화 척도의 효과를 검증할 수 있었다. 이는 여러 반복 실험을 통해 제안하는 방법을 통해 낙상 감지 시간을 단축할 뿐만 아니라 감지 정확도도 향상하는 것을 확인할 수 있었다. 이러한 결과는 우리의 목적에 제대로 부합하는 방법을 만들었음을 보여주었다.

이 논문에서 제안된 발화 측정을 낙상 감지로 제한할 이유는 없다. EMD는 단순히 통계적으로 보고할 수 있는 값이 아니라, 이 논문을 통해 실제 단 한 번의 수행 내에서도 적용될 수 있음을 입증했기 때문이다. 외골격 로봇의 동기화 문제와 같이 인간-로봇 상호작용 분야에서 EMD가 실제 응용될 수 있

를 기다리고 있다. 따라서 향후 이루어질 연구는 다른 동작을 포함할 뿐만 아니라, 더 나아가 EMD의 보장이 필요한 다양한 분야에 제안한 방법을 적용할 필요가 있을 것이다.

References

- [1] R. Rajagopalan, I. Litvan, and T.-P. Jung, "Fall prediction and prevention systems: Recent trends, challenges, and future research directions," *Sensors*, vol. 17, no. 11, pp. 2509, Nov., 2017, DOI: 10.3390/s17112509.
- [2] B. Kwolek and M. Kepski, "Human fall detection on embedded platform using depth maps and wireless accelerometer," *Computer Methods and Programs in Biomedicine*, vol. 117, no. 3, pp. 489-501, Dec., 2014, DOI: 10.1016/j.cmpb.2014.09.005.
- [3] L. Martínez-Villaseñor, H. Ponce, J. Brieua, E. Moya-Albor, J. Nunez-Martinez, and C. Peñafort-Asturiano, "Up-fall detection dataset: A multimodal approach," *Sensors*, vol. 19, no. 9, pp. 1988, Apr., 2019, DOI: 10.3390/s19091988.
- [4] E. Casilari, J. A. Santoyo-Ramón, and J. M. Cano-García, "Umalfall: A multisensor dataset for the research on automatic fall detection," *Procedia Computer Science*, vol. 110, pp. 32-39, 2017, DOI: 10.1016/j.procs.2017.06.110.
- [5] J. Cheng, X. Chen, and M. Shen, "A framework for daily activity monitoring and fall detection based on surface electromyography and accelerometer signals," *IEEE Journal of Biomedical and Health Informatics*, vol. 17, no. 1, pp. 38-45, Jan., 2013, DOI: 10.1109/TITB.2012.2226905.
- [6] X. Xi, M. Tang, S. M. Miran, and Z. Luo, "Evaluation of feature extraction and recognition for activity monitoring and fall detection based on wearable sEMG sensors," *Sensors*, vol. 17, no. 6, pp. 1229, May, 2017, DOI: 10.3390/s17061229.
- [7] X. Liu, H. Li, C. Lou, T. Liang, X. Liu, and H. Wang, "A new approach to fall detection based on improved dual parallel channels convolutional neural network," *Sensors*, vol. 19, no. 12, pp. 2814, Jun., 2019, DOI: 10.3390/s19122814.
- [8] N. Sharma, C. M. Gregory, and W. E. Dixon, "Predictor-based compensation for electromechanical delay during neuromuscular electrical stimulation," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 19, no. 6, pp. 601-611, Dec., 2011, DOI: 10.1109/TNSRE.2011.2166405.
- [9] H. Begovic, G.-Q. Zhou, T. Li, Y. Wang, and Y.-P. Zheng, "Detection of the electromechanical delay and its components during voluntary isometric contraction of the quadriceps femoris muscle," *Frontiers in Physiology*, vol. 5, Dec., 2014, DOI: 10.3389/fphys.2014.00494.
- [10] S. U. Yavuz, A. Sendemir-Urkmez, and K. S. Turker, "Effect of gender, age, fatigue and contraction level on electromechanical delay," *Clinical Neurophysiology*, vol. 121, no. 10, pp. 1700-1706, Oct., 2010, DOI: 10.1016/j.clinph.2009.10.039.
- [11] E. N. Kamavuako, E. J. Scheme, and K. B. Englehart, "Determination of optimum threshold values for emg time domain features; a multi-dataset investigation," *Journal of Neural*

- Engineering*, vol. 13, no. 4, pp. 046011, Jun., 2016, DOI: 10.1088/1741-2560/13/4/046011.
- [12] I. J. R. Martinez, A. Mannini, F. Clemente, A. M. Sabatini, and C. Cipriani, "Grasp force estimation from the transient emg using high-density surface recordings," *Journal of Neural Engineering*, vol. 17, no. 1, pp. 016052, Feb., 2020, DOI: 10.1088/1741-2552/ab673f.
- [13] I. Conradsen, S. Beniczky, K. Hoppe, P. Wolf, and H. B. D. Sorensen, "Automated algorithm for generalized tonic-clonic epileptic seizure onset detection based on sEMG zero-crossing rate," *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 2, pp. 579-585, Feb., 2012, DOI: 10.1109/TBME.2011.2178094.
- [14] X. Li, P. Zhou, and A. S. Aruin, "Teager-kaiser energy operation of surface emg improves muscle activity onset detection," *Annals of Biomedical Engineering*, vol. 35, no. 9, pp. 1532-1538, May, 2007, DOI: 10.1007/s10439-007-9320-z.
- [15] S. E. Selvan, D. Alexandre, U. Amato, and G. H. Yue, "Unsupervised stochastic strategies for robust detection of muscle activation onsets in surface electromyogram," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 6, pp. 1279-1291, Jun., 2018, DOI: 10.1109/TNSRE.2018.2833742.
- [16] Q. Xu, Y. Quan, L. Yang, and J. He, "An adaptive algorithm for the determination of the onset and offset of muscle contraction by emg signal processing," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 21, no. 1, pp. 65-73, Jan., 2013, DOI: 10.1109/TNSRE.2012.2226916.
- [17] E. S. Suviseshamuthu, D. Alexandre, U. Amato, B. D. Vecchia, and G. H. Yu, "Prolific: A fast and robust profile-likelihood-based muscle onset detection in electromyogram using discrete fibonacci search," *IEEE Access*, vol. 8, pp. 105362-105375, 2020, DOI: 10.1109/ACCESS.2020.3000693.
- [18] N. M. López, E. Orosco, and F. D. Sciascio, "Surface electromyographic onset detection based on statistics and information content," *Journal of Physics: Conference Series*, vol. 332, pp. 012043, 2011, DOI: 10.1088/1742-6596/332/1/012043.
- [19] Y. Kuroda, I. Nisky, Y. Uranishi, M. Imura, A. M. Okamura, and O. Oshiro, "Novel algorithm for real-time onset detection of surface electromyography in step-tracking wrist movements," *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, Japan, pp. 2056-2059, 2013, DOI: 10.1109/EMBC.2013.6609936.
- [20] J. Liu, D. Ying, W. Z. Rymer, and P. Zhou, "Robust muscle activity onset detection using an unsupervised electromyogram learning framework," *PloS one*, vol. 10, no. 6, pp. e0127990, Jun., 2015, DOI: 10.1371/journal.pone.0127990.
- [21] I. Conradsen, S. Beniczky, K. Hoppe, P. Wolf, T. Sams, and H. B. D. Sorensen, "Seizure onset detection based on one semg channel," *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, MA, USA, pp. 7715-7718, 2011, DOI: 10.1109/IEMBS.2011.6091901.
- [22] T. D. Sanger, "Bayesian filtering of myoelectric signals," *Journal of neurophysiology*, vol. 97, no. 2, pp. 1839-1845, Feb., 2007, DOI: 10.1152/jn.00936.2006.
- [23] S. Park, W. K. Chung, and K. Kim, "Training-Free Bayesian Self-Adaptive Classification for sEMG Pattern Recognition Including Motion Transition," *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 6, pp. 1775-1786, Jun., 2020, DOI: 10.1109/TBME.2019.2947089.



박 성 식

2010 서울대학교 기계항공공학부(학사)
 2019 POSTECH 기계공학과(박사)
 2023~현재 한국방송통신대학교 조교수

관심분야: 생체 신호, 로봇 제어, 컴퓨터 비전



김 기 훈

1999 포항공과대학교 기계공학과(학사)
 2001 포항공과대학교 기계공학과(석사)
 2006 포항공과대학교 기계공학과(박사)
 2019~현재 포항공과대학교 부교수

관심분야: 바이오-의료 로봇, 재활로봇, 바이오닉스, 햅틱스