

대퇴의족의 자동 보행 모드 변경을 위한 랜덤 포레스트 기반 추정 모델 개발에 관한 연구

A Study on Random Forest-based Estimation Model for Changing the Automatic Walking Mode of Above Knee Prosthesis

나 선 종*, 신 진 우*, 엄 수 홍*, 이 응 혁*★

Sun-Jong Na*, Jin-Woo Shin*, Su-Hong Eom*, Eung-Hyuk Lee*★

Abstract

The pattern recognition or fuzzy inference, which is mainly used for the development of the automatic walking mode change of the above knee prosthesis, has a disadvantage in that it is difficult to estimate with the immediate change of the walking environment. In order to solve a disadvantage, this paper developed an algorithm that automatically converts the walking mode of the next step by estimating the walking environment at a specific gait phase. Since the proposed algorithm should be implanted and operated in the microcontroller, it is developed using the random forest base in consideration of calculation amount and estimated time. The developed random forest based gait and environmental estimation model were implanted in the microcontroller and evaluated for validity.

요 약

의족의 자동 보행 모드 변경 알고리즘 개발에는 주로 사용되는 패턴 인식 또는 퍼지 추론 기법을 이용하지만 즉각적인 보행 환경 변화에는 대응하기 어렵다는 단점을 가진다. 이러한 한계점을 해결하고자 본 논문에서는 한 보행 주기 내 특정 보행 단계에서의 보행 환경 추정을 통해 다음 걸음의 보행 모드를 자동으로 변환하는 알고리즘을 개발하였다. 제안하는 알고리즘은 마이크로 컨트롤러 내에 이식되어 운용되어야 하므로 계산량과 추정 소요 시간을 고려하여 랜덤포레스트 기반을 사용하여 개발하였다. 개발된 랜덤포레스트 기반의 보행 단계 및 환경 추정 모델은 마이크로 컨트롤러 내에 이식되어 유효성 평가를 진행하였다.

Key words : automatic walking mode change, above knee prosthesis, machine learning, random forest

* Dept. of Electronics Engineering, Korea Polytechnic University

★ Corresponding author

E-mail : ehlee@kpu.ac.kr, Tel : +82-31-8041-0477

※ Acknowledgment

This research was supported by the Bio & Medical Technology Development Program of the NRF funded by the Korean government, MSIP (NRF-2017M3A9E2063260)

This research was supported by the MSIT (Ministry of Science and ICT), Korea, under the ITRC (Information Technology Research Center) support program (IITP-2020-2018-0-01426) supervised by the IITP (Institute for Information & Communications Technology Planning & Evaluation)

Manuscript received Mar. 6, 2020; revised Mar. 21, 2020; accepted Mar. 26, 2020.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://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.

1. 서론

국내 등록 장애인 수는 매년 증가하고 있으며, 2017년도 기준 지체 장애인 중 절단으로 인한 지체 유형은 약 17.1%로 집계되고 있으며, 지체 장애 부위로는 46.3%로 하지절단이 가장 많다[1].

하지절단은 절단 부위에 따라서 대퇴, 슬관절 이단, 하퇴, 족부 등으로 나눌 수 있다. 그 중 대퇴절단 환자는 다른 하지 절단 부위에 비해 하지의 잔존 부위가 가장 적기 때문에 보행 시 제약이 가장 크다. 따라서 대퇴절단 환자의 보행을 지원하기 위해 사용되는 보조기기는 지금도 다양하게 연구되고 있으며, 그 중 신체 대체 기기 기술로는 대퇴의족이 있다.

대퇴의족은 나날이 발전하고 있으며 최근에는 기존 의족보다 가볍고 에너지가 덜 소모되는 하이브리드형 의족이 연구되고 있다. 이러한 의족은 Ottobock사의 Genium 등이 있으며 보행 환경에 맞는 보행 모드에 따라 최적화된 보행 궤적을 생성하기 위해 마이크로컨트롤러를 활용하여 실린더의 저항력을 가변 제어한다.

과거 보행 모드의 변경 방법으로는 생체신호(EMG)를 활용한 방법, 사용자가 외부의 리모트 컨트롤러를 조작하여 변경하는 방법 등이 사용되어 왔다[2-4]. 하지만 이러한 방식은 사용자가 직접 보행 노면을 파악하고 모드를 변경해야 하는 불편함이 있으며, 사용자의 조작 실수 또는 생체신호의 품질 문제로 인하여 오작동을 유발할 수 있다. 의족의 오작동은 의족 착용자의 낙상을 유발하는 큰 위험이 될 수 있다.

이러한 문제를 개선하기 위하여 최근에는 의족 내에 센서를 탑재하고 취득되는 데이터를 바탕으로 사용자의 보행 의도나 현재 보행중인 노면을 파악하고 그에 따른 보행 궤적을 만들어주는 자동 보행 모드 전환 방식이 연구되고 있다[5-7].

패턴 인식 방법은 움직임의 패턴을 분석하여 알고리즘으로 전환하고, 이후 패턴이 인식되면 해당하는 패턴에 따른 동작을 지원하는 방식으로 인식 정확도가 높다[8]. 하지만 인식을 위해 몇 걸음 이상의 보행이 필요하며 알고리즘 개발을 위한 특징값을 추출하는 부분에서 시간이 오래 걸린다는 단점이 있다.

과거 추론 방법은 명확하게 구분하기 어려운 물

리량에 대하여 애매모호한 경계를 명확히 하여 추론하는 방식이다[9]. 분석에 편리하지만 주관적으로 경계가 결정되며 패턴 인식 방법과 동일하게 인식을 위해 몇 걸음 이상의 보행이 필요하다는 단점이 있다.

현재 개발된 두 방식 모두 급변하는 환경에 대해서는 추정할 수 없기 때문에 이에 대한 대응 기술이 필요하다. 따라서 본 논문에서는 머신러닝 기법을 이용하여 보행 시 특정 보행 단계에서 보행 환경을 추정하고 자동으로 다음 걸음의 보행 모드를 변경하는 기법을 제안하고자 한다. 개발된 두 방식과는 다르게 보행 한 걸음 내에서 보행 환경을 추정하고자 하며, 컴퓨터가 보행 단계 및 환경이 입력된 센서 데이터를 이용하여 학습시킨다. 학습으로 생성된 보행 단계 및 환경 추정 모델을 이용하여 자동으로 보행 모드를 변경하고자 한다.

현재 머신러닝을 활용한 유사 연구로써 H. F. Maqbool은 의족 착용자의 정강이 부분에 부착된 관성센서를 이용하여 휴리스틱 기반의 알고리즘을 개발, 초기접지기와 Toe-off를 100%로 추정하였다[10]. Heo는 순환형 신경망에 무릎각도의 변화량과 양쪽 고관절에 부착한 관성센서를 이용하여 초기 접지기와 Toe-off를 약 97%로 추정하였다[11]. 두 연구 모두 입각기의 두 단계만을 추정하였기 때문에 이를 이용한 보행 환경 추정은 어려울 것으로 판단한다. 본 논문에서 제안하는 추정 기법을 위해서는 좀 더 세분화된 보행 단계로 추정할 필요가 있다.

따라서 본 논문에서는 무릎각도와 관성센서 데이터를 이용하여 보행 시 입각기 3단계와 유각기를 추정하고, 특정 보행 단계에서 보행 환경(경사로 상행, 평지, 경사로 하행)을 추정하여 자동으로 의족의 보행 모드를 변경하는 방식을 제안한다.

제안하는 방식은 기존 개발된 무릎각도 변화를 이용한 보행 단계 추정 알고리즘의 정상인의 보행에만 적용 가능한 한계점과 경사로 상행/하행 및 평지에서 고관절 각도의 유사성으로 인한 보행 환경 추정 알고리즘 개발의 어려움을 개선하고자 머신러닝 기법을 이용하여 개발하고자 한다.

또한 제안하는 무릎각도와 관성센서 데이터를 이용한 머신러닝 기법의 유효성을 검증하고자 한다. 이를 위해 의족 제어에 사용되는 저가의 마이크로컨트롤러 및 소형 임베디드 시스템에 이식하여 랜

덤포레스트 기반 추정 알고리즘의 정확도를 시뮬레이션을 통해 비교한다. 이를 통해 학습에 사용하지 않은 데이터가 입력되어도 추정 정확도가 크게 저하되지 않는다는 결과를 도출하고자 한다.

II. 본론

제안하는 기법은 보행 한 걸음 내 보행 정보를 이용하여 보행 단계를 추정하고 특정 보행 단계에서 보행 환경을 추정하여 다음 걸음의 보행 모드를 자동으로 변경하는 것이다. 이러한 기법을 개발하기 위해 본 논문에서는 보행 단계 및 보행 환경 추정 알고리즘을 개발하고자 한다.

해당하는 알고리즘은 다양한 방법으로 개발되고 있지만 의족 착용자의 경우 절단면, 절단 길이, 보행 습관에 따라 센서로부터 취득되는 데이터가 상이하다. 따라서 정형화된 알고리즘을 개발하는 것은 어려운 실정이다. 또한 사람이 알고리즘 개발을 위해 직접 데이터를 보고 분석하는 경우 전문지식이 필요하며, 시간이 많이 소비된다.

따라서 이러한 문제를 개선하기 위해 본 논문에서는 인간이 직접 추정하기 모호한 데이터를 컴퓨터가 입력된 레이블(label)에 따라 스스로 학습한 후 추정 모델을 생성하는 머신러닝을 이용하는 알고리즘을 개발하고자 한다.

1. 보행 단계 및 환경 추정 알고리즘 분석

본 절에서는 기존에 개발된 보행 단계 및 보행 환경 추정 알고리즘의 한계점을 파악하고 이를 해결하기 위한 머신러닝 기반 알고리즘 개발의 필요성에 대해 설명하고자 한다.

가. 무릎각도를 이용한 보행 단계 추정 기법 분석

보행 단계를 추정하기 위한 연구로는 크게 두 가지 방법의 연구가 진행되어오고 있다. 첫 번째 방법은 지면반발력을 이용하여 보행 단계를 추정하는 방법[12], 두 번째 방법은 무릎각도의 변화를 이용하여 보행 단계를 추정하는 방법이다[13].

지면반발력을 이용한 보행 단계를 추정하는 방법은 보편적으로 발의 발뒤꿈치와 발가락 끝에 FSR (force sensitive resistor)센서를 부착하여 보행 단계를 추정한다. 하지만 보행 시 센서에 직접적으로 압력이 작용하기 때문에 시간이 지날수록 측정 범

위가 줄어들고 변형으로 인한 드리프트 현상이 발생할 수 있어 장기적으로는 사용할 수 없는 단점이 있다.

따라서 본 논문에서는 무릎각도의 변화에 따른 보행 단계를 추정하는 방법을 분석하고자 한다. 무릎각도의 변화에 따른 보행 단계 추정 방법은 보행 시 무릎각도의 최대 굴곡과 신전 궤적에서의 변곡 지점을 이용하여 보행 단계를 추정한다.

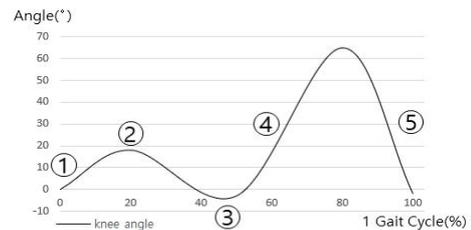


Fig. 1. Knee angle changes of normal persons during flat walking.

그림 1. 평지 보행 시 정상인의 무릎각도 변화

정상인의 평지 보행 시 무릎각도는 그림 1처럼 굴곡과 신전이 2차례씩 발생한다. 이러한 굴곡과 신전은 입각기에서 몸을 지지하는 과정과 유각기에서 신체를 전방으로 기울이며 발을 들어 앞으로 이동하는 과정에서 발생한다. 정상적인 보행일 경우 무릎각도 범위는 0°~70°로 사람에 따라 어느 정도 차이가 있지만 대부분 비슷한 형태를 가지고 있다.

정상인의 보행 주기는 보행 시 발생하는 무릎각도의 변곡지점을 바탕으로 보행 시작부터 첫 번째 변곡지점까지가 초기접지기(①), 이후 두 번째 변곡지점까지가 중간입각기(②), 이후 세 번째 변곡지점까지가 말기입각기(③), 이후 마지막 변곡지점을 중심으로 초기유각기(④)와 말기유각기(⑤)를 쉽게 추정할 수 있다[13].

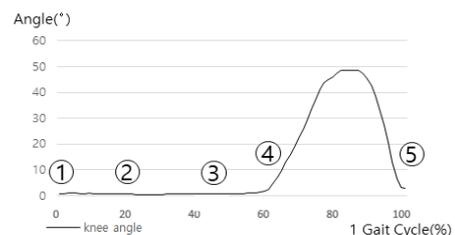


Fig. 2. Knee angle changes of prosthesis user during flat walking.

그림 2. 평지 보행 시 의족 착용자의 무릎각도 변화

반면 유압형 실린더 기반의 수동형 대퇴 의족인 Ottobock사의 3R60의 보행 한 주기 내 무릎각도 변화 그래프는 그림 2와 같다.

의족 착용자의 무릎각도 변화 그래프를 보면 무릎이 구부러지며 유각기가 시작되고 지면에서 발을 떼고 다음 보행을 위해 무릎이 펴지는 유각기(④, ⑤)에서는 정상인과 동일하게 무릎각도의 변곡지점을 이용하여 추정이 가능하다.

하지만 입각기(①, ②, ③)에서는 수동형 대퇴의족이 착용자의 체중을 지지하기 위한 지지대의 역할을 위해 무릎이 고정되기 때문에 무릎각도의 변화가 거의 없어 입각기의 세부 단계를 추정하는 것의 어려움을 확인할 수 있다.

나. 고관절 각도를 이용한 환경 추정 기법 분석

본 논문에서는 관성센서를 의족 소켓의 외부에 부착하는 것으로 가정하기 때문에 고관절 각도 변화 이용한 보행 환경 추정 기법에 대하여 분석하였다.

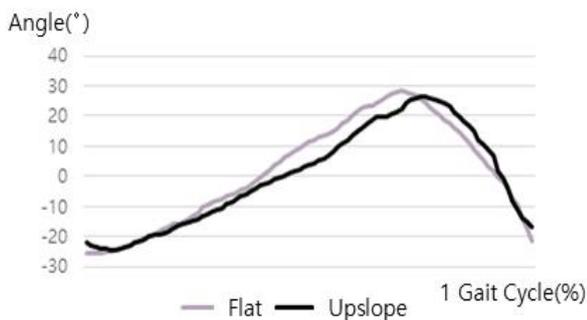


Fig. 3. Hip angle change of gait on flat, upslope.
 그림 3. 경사로 상행, 평지에서 고관절 각도 변화

그림 3은 경사로 상행과 평지에서 측정한 보행 한 주기 내 고관절 각도 변화 그래프다. 경사로 상행의 경우 발목이 지면각도에 적응하면서 몸의 무게 중심이 앞으로 옮겨지게 되기 때문에 경사로 상행에서 취득되는 관성센서 데이터는 평지에서 취득되는 관성센서 데이터와 매우 유사하다. 따라서 이러한 데이터를 이용하여 사람이 직접 분석하고 추정 알고리즘을 개발하는 데는 한계가 있다.

따라서 무릎각도의 변화를 이용한 입각기의 세부 단계를 구분할 수 없다는 한계점과 경사로 상행과 평지에서의 데이터 유사성으로 인해 제안하는 알고리즘을 개발하는 것에 제한이 있다. 따라서 사람이 직접 추정 알고리즘을 개발의 어려움을 해결하

기 위해 본 논문에서는 데이터 집합을 구축하여 컴퓨터가 스스로 데이터를 가지고 학습한 후 추정 알고리즘을 생성하는 머신러닝 기반의 보행 단계 및 환경 추정 모델을 개발하고자 한다.

이를 이용하면 대퇴 절단면, 절단 후 잔존 대퇴 길이, 보행 습관에 따라 취득되는 데이터가 달라져도 학습에 사용된 데이터 집합 내 유사한 보행 데이터를 가진 데이터를 이용하여 쉽게 보행 단계 및 보행 환경 추정 알고리즘의 생성이 가능할 것으로 판단한다.

다. 추정을 위한 머신러닝 기법 선정

본 논문에서는 무릎각도와 관성센서를 이용한 보행 단계 및 환경 추정의 한계점을 개선하고자 한다. 이를 위해서는 레이블이 명시되지 않은 데이터를 이용하는 비지도 학습이나 환경에 따라 최대한 많은 보상을 받을 수 있도록 최적의 행동을 스스로 학습하는 강화학습보다는 레이블이 명시된 데이터를 사용하여 학습하고 입력 데이터에 따라 출력 데이터가 나오는 지도학습을 사용하여 추정 모델을 생성하는 것이 더 알맞다고 할 수 있다.

지도학습의 종류로는 SVM(Support Vector Machine), 인공신경망, 의사결정나무 등이 있다[16]–[17]. 본 논문에서 개발된 머신러닝 기반 보행 단계 및 보행 환경 추정 모델은 의족 내 마이크로 컨트롤러에 이식되어야 한다. 이를 위해서는 계산량이 많지 않고 추정하는데 소요되는 시간이 짧은 기법을 사용해야 한다.

지도학습 기법 중 의사결정나무의 학습 결과는 기존의 제어 알고리즘에 사용되는 threshold과 유사하며, 추정을 위한 계산량이 복잡하지 않다. 그러므로 마이크로 컨트롤러에 학습 결과를 이식하는 것은 어렵지 않을 것으로 판단한다. 하지만 지나치게 학습 데이터에만 일반화되는 과대적합이 발생할 위험이 있다. 이러한 과대적합의 위험은 독립적인 의사결정나무의 결과값을 이용하는 랜덤포레스트 기법을 통해서 해결이 가능하다.

따라서 본 논문에서는 의족 내 마이크로 컨트롤러에 이식을 고려하여 계산량과 추정 소요 시간이 비교적 짧은 의사결정나무의 응용 기법인 랜덤포레스트를 이용하여 보행 단계 및 보행 환경 추정 모델을 개발하고자 한다.

가. 랜덤포레스트

랜덤포레스트(random forest)는 단일 머신러닝 알고리즘의 예측력을 높이기 위해 다중의 머신러닝 알고리즘을 융합하는 앙상블 학습 방법의 일종으로 훈련 과정에서 구성된 다수의 의사결정나무로부터 출력되는 각각의 추정 결과를 이용하여 분류하는 방법이다[18].

랜덤포레스트는 데이터 집합의 원본으로부터 각각의 부트스트랩 샘플을 생성하고, 이를 이용하여 생성된 의사결정나무 모델은 입력 데이터가 주어질 시 각각의 출력 결과를 종합하여 추정한다.

랜덤포레스트는 데이터 집합의 원본을 속성별로 하나씩 나눈 후 이를 무작위로 추출하는 반복추출 방식을 이용하여 원래 데이터의 수만큼 크기를 갖도록 샘플링하여 부트스트랩 샘플을 생성한다.

생성된 샘플은 majority voting 방식을 이용하여 입력데이터를 분류한다. 이러한 방식은 각각의 추정 결과를 종합하고 입력된 데이터에 대한 추정을 출력하며 식 (1)과 같이 표현 할 수 있다.

$$Ensemble(y') = \underset{i \in \{Gait\ Phase\ or\ Walking\ Invironment\}}{\operatorname{argmax}} \left(\sum_{j=1}^n (y'_j = i) \right) \quad (1)$$

y' 은 j 번째 의사결정나무에서 입력데이터에 대한 추정 결과이며, i 에 포함되는 *Gait Phase*는 본 논문에서 추정하고자 하는 보행 단계, *Walking Invironment*는 본 논문에서 추정하고자 하는 보행 환경이다. *Ensemble(y')*에서는 각각 의사결정나무의 추정 결과를 종합하여 가장 많은 빈도수를 가지는 추정 결과를 랜덤포레스트의 최종적인 추정으로 출력하게 된다.

랜덤포레스트는 다른 지도학습 기반 모델들과 달리 매개변수의 튜닝 없이도 학습이 가능하며 데이터의 스케일링을 필요로 하지 않는다는 것이다. 이는 의족 내의 마이크로 컨트롤러에 이식할 때 입력되는 데이터에 대하여 전처리 과정이 없어 추정 소요 시간이 다른 모델에 비해 짧다.

2. 추정모델의 학습을 위한 데이터 집합 구축

랜덤포레스트의 학습을 위한 데이터 집합을 구축하기 위한 전제조건은 입력된 데이터에 대하여 정확한 추정이 가능하도록 해당하는 데이터에 대한 정확한 레이블 입력과 구축한 데이터 집합의 신뢰

도가 높아야 한다.

본 논문에서는 보행 단계 및 보행 환경 추정 모델 생성을 위해 무릎각도의 변화와 관성센서로부터 취득되는 가속도 3축과 각속도 3축 및 이를 이용하여 산출 가능한 각도 Roll, Pitch, Yaw를 속성으로 가지는 데이터 집합을 구축하고자 한다. 추가적으로 해당하는 각각의 보행 단계 및 보행 환경을 레이블을 직접 입력하고자 한다.

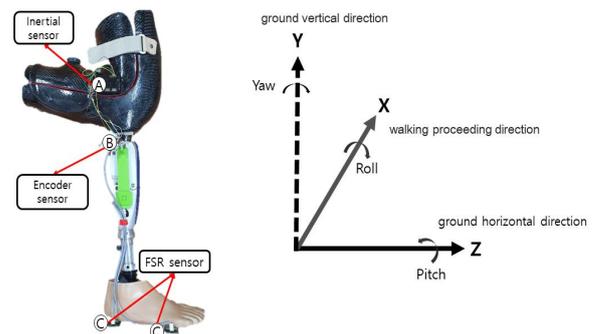


Fig. 4. Passive prosthetic adapter, sensor attachment location and coordinate system used to build the data set.

그림 4. 데이터 집합 구축을 위해 사용된 수동형 의족 어댑터, 센서 부착 위치와 좌표계

그림 4는 랜덤포레스트 기반 추정 모델의 학습을 위한 데이터 집합을 구축하기 위해 사용된 수동형 의족과 각각의 센서 부착 위치, 사용된 좌표계다.

학습 시 많은 학습 데이터를 사용할수록 일반화가 잘 된 추정 모델을 만들 수 있지만, 실제 대퇴 절단 환자를 대상으로 학습을 위한 충분한 양의 데이터를 수집하기에는 한계가 있다. 따라서 본 논문에서는 정상인이 대퇴 절단 환자의 보행 데이터를 만들 수 있도록 의족이 장착된 어댑터를 착용하여 데이터를 수집하였다.

의족에 부착한 센서 중 (A)는 관성센서로 의족 어댑터의 표면에 부착하여 보행 시 부착위치에서의 가속도 3축과 각속도 3축, 이를 이용하여 산출되는 각도 데이터를 취득한다. (B)는 엔코더 센서로 보행 시 무릎각도의 변화를 측정한다. (C)는 압력센서인 FSR로 정확한 보행 단계 구분을 위해 사용되었으며, 발가락의 끝 부분과 발뒤꿈치에 부착하고 보행 시 발생하는 지면반발력을 측정하여 4개의 보행 단계를 데이터 집합의 레이블로 입력하였다. 각 센서의 사양은 아래 표 1과 같다.

Table 1. Specification of each sensor used to build the data set.

표 1. 데이터 집합 구축에 사용된 각 센서의 사양

Sensor type	Specification
Inertial sensor	NGIMU (x-io) Communication speed: 50 Hz Communication method: Wifi
Encoder sensor	SAE360C-X05-W(Absolute)
Pressure sensor	FSR402 (10N Sensitivity)

표 1의 센서가 부착된 의족 어댑터를 70kg 2명, 80kg 2명의 정상인이 착용하고 각 보행 환경에서 30cm의 보폭으로 5걸음 보행을 10회 반복하였다. 각각의 센서로부터 취득된 데이터를 모아 데이터 집합을 구축하였다.

본 논문에서 구축한 데이터 집합은 전문가관을 통하여 측정된 것이 아니기 때문에 추정 모델을 생성하기 위해 학습시키기 전 구축한 데이터 집합이 올바른 데이터인지 신뢰도의 판단이 필요하다. 신뢰도가 낮은 데이터를 이용한 학습은 학습 과정에서 모델의 정확도에 치명적인 문제가 발생할 수 있으며 학습 후 만들어진 추정 모델 또한 신뢰하기 어려워진다.

따라서 본 논문에서는 신뢰도 판단을 위해 본 논문에서 사용한 의족과 동일한 구조로 동작하는 유압형 실린더 수동형 의족(Mouch SNS knee)의 무릎각도 및 고관절 각도를 비교하였다[19].

모두 비슷한 양상을 보였지만 고관절 각도의 최대 각도와 최소 각도 크기에서 차이가 있었다. 이는 타 논문에서는 소켓 내부에서 측정된 것과 달리 본 논문에서는 의족 어댑터의 외부에 부착하였으므로 부착 위치에 따른 차이로 판단된다.

따라서 본 논문에서 생성한 데이터 집합은 측정 시 오류가 없었으며 신뢰도가 높다고 판단하고, 이를 이용하여 제안하는 추정 기법에 필요한 보행 단계 및 보행 환경 추정 모델을 생성하고자 한다.

3. 랜덤포레스트 기반 자동 보행 모드 변경 기법 개발

본 절에서는 랜덤포레스트 기반의 보행 단계 및 보행 환경 추정 모델을 생성하고 부트스트랩 샘플 수에 따른 정확도를 비교하고자 한다.

보행 단계는 추후 보행 환경에 따른 보행 궤적 생성을 고려하여 초기입각기, 중간입각기, 말기입각기, 유각기 총 4개로 나누어 구분하고자 한다.

보행 환경은 평지, 경사로 상행, 경사로 하행을 추정하는 것을 목표로 한다. 경사도가 낮은 경우(2° ~ 4°)는 평지 보행과 큰 차이가 없지만 경사도가 높은 경우(6° 이상) 보행을 위한 궤적 생성이 필요하기 때문이다.

본 논문에서는 생성된 모델을 학습 데이터를 이용한 5점 교차 검증 정확도와 학습에 사용하지 않은 데이터를 이용한 검증 데이터 정확도, 총 2개를 이용하여 모델의 성능을 평가하였다.

본 논문에서 학습을 위해 사용한 소프트웨어는 Python을 사용하였으며 학습에는 scikit-learn, sklearn 기반의 라이브러리를 이용하였다.

가. 랜덤포레스트 기반 보행 단계 추정 모델 생성
자동 보행 모드 변경 시 및 본 논문에서 제안하는 특정 보행 단계에서의 보행 환경 추정 기법을 위해 랜덤포레스트 기반의 추정 모델을 생성하고 부트스트랩 샘플 수에 따른 정확도를 비교한다.

평지 뿐 만 아니라 본 논문에서 추정하고자 하는 경사로 상행, 경사로 하행에서도 보행 단계를 추정할 수 있어야 한다. 따라서 본 논문에서 개발하는 보행 단계 추정 모델은 보행 환경에 상관없이 보행 단계를 추정할 수 있도록 학습해야 한다.

마이크로 컨트롤러에 이식을 고려하여 부트스트랩 샘플의 깊이는 3으로 고정하였다. 추정 소요 시간 기준은 일반적인 보행 속도를 고려하여 센서의 샘플링 주기인 500Hz를 기준으로 한다. 따라서 학습을 통해 생성된 모델이 하나의 샘플을 분류하는데 소요 시간이 2ms 이하인 부트스트랩 샘플의 개수에 따른 정확도는 표 2와 같다.

Table 2. Accuracy of gait pahse estimation in random forest according to Bootstrap Samples.

표 2. 부트스트랩 샘플의 개수에 따른 랜덤포레스트의 보행 단계 추정 정확도

Bootstrap sample	Accuracy	
	Cross validation accuracy	Validation data accuracy
5	92.5%	90.3%
10	95.4%	93.9%
20	97.1%	96.3%
30	98.8%	97.4%
40	99.0%	97.9%
50	99.1%	98.1%

부트스트랩 샘플의 개수가 많아짐에 따라 정확도가 증가하는 것을 확인할 수 있으며, 30개 이후부터는 교차 검증 정확도와 검증 데이터 정확도의 상승 폭이 30개 이하보다 매우 줄어든 것을 확인할 수 있다. 정확도가 가장 높은 모델을 사용하는 것보다 정확도가 0.3% 내외로 낮아져도 계산량이 적은 모델을 이식하는 것이 좋을 것이라고 판단하였다.

따라서 본 논문에서 마이크로컨트롤러에 이식하고자 하는 하나의 샘플을 추정하는데 소요 시간이 2ms 이하인 랜덤포레스트 기반의 보행 단계 추정 모델은 30개의 부트스트랩 샘플을 가지는 모델임을 확인할 수 있다.

나. 랜덤포레스트 기반 보행 환경 추정 모델 생성
보행 환경 추정 모델을 생성하는 방법은 3-가와 동일한 방법으로 구축한 데이터 집합을 이용하여 랜덤포레스트 기반의 보행 환경 추정 모델을 생성하고 각각의 추정 정확도를 비교한다.

보행 환경 추정 모델의 추정 소요 시간 기준은 3-가와 동일하게 하나의 샘플을 분류하는데 2ms 이하의 분류 소요 시간을 소요하는 모델만 선정하여 정확도를 비교하였다.

부트스트랩 샘플의 깊이는 모델의 정확성을 고려하여 5로 고정하였으며 하나의 샘플을 분류하는데 소요 시간이 2ms 이하인 부트스트랩 샘플의 개수에 따른 정확도는 표 3과 같다.

Table 3. Accuracy of walking environment estimation in random forest according to Bootstrap Samples.

표 3. 부트스트랩 샘플의 개수에 따른 랜덤포레스트의 보행 환경 추정 정확도

Bootstrap sample	Accuracy	
	Cross validation accuracy	Validation data accuracy
5	81.5%	74.7%
10	88.7%	79.6%
15	88.4%	83.1%
20	89.2%	85.6%
25	91.7%	90.3%
30	92.4%	91.7%

보행 단계 추정 모델과 동일하게 부트스트랩 샘플의 개수가 많아짐에 따라 정확도가 증가하는 것을 확인할 수 있다. 또한 제한된 분류 소요 시간을

고려하였을 때, 보행 단계 추정 모델보다 부트스트랩 샘플의 최대 개수가 줄어들었음을 확인할 수 있다. 이는 부트스트랩 샘플의 깊이가 보행 단계 추정 모델보다 깊어졌기 때문이다.

본 논문에서 마이크로컨트롤러에 이식하고자 하는 하나의 샘플을 추정하는데 소요 시간이 2ms 이하인 랜덤포레스트 기반의 보행 환경 추정 모델은 30개의 부트스트랩 샘플을 가지는 모델임을 확인할 수 있다.

4. 실험 및 고찰

개발된 보행 단계 및 환경 추정 모델은 의족 내의 마이크로컨트롤러에 이식되어야 하며 학습에 사용되지 않은 새로운 데이터가 입력되어도 현재 보행에 맞는 보행 단계 및 보행 환경을 추정하여야 한다. 따라서 본 절에서는 학습에 사용하지 않은 새로운 데이터를 추정 기법에 입력하였을 시의 정확도 산출 및 비교하기 위해 실험 환경을 구성하고 데이터를 취득하고자 한다.



Fig. 5. Configure experimental environment for data acquisition.
그림 5. 데이터 취득을 위한 실험 환경 구성

본 논문에서 생성한 추정 모델의 유효성 평가를 위해 구성된 실험 환경은 그림 5와 같다. 의족 어댑터의 의족은 Ottobock사의 3R60을 사용하였다. 앞서 데이터 집합 구축 과정에서 참여하지 않은 약 60kg 정상인의 데이터를 취득하였다. 관성센서 부착 위치는 데이터 집합 구축 시 부착한 위치와 동일한 곳에 부착하였으며, 센서 샘플링 주기는 앞의 과정과 동일하게 500Hz로 하였다. 보행 실험 환경은 재활공학연구소의 재활운동실의 평지와 약 8°의 기울기를 가지는 오름-내림 경사로에서 무릎각도와 관성센서 데이터를 취득하였다.

분류를 위한 마이크로컨트롤러는 추정을 위한 계

산량과 모델 이식 시 메모리 크기, 추후 실시간으로 센서 데이터를 취득하기 위한 SPI, I2C 통신, UART, ADC(analog-to-digital converter) 기능을 고려하여 pyboard를 사용하였다.

가. 보행 단계 추정 정확도 비교

3절에서 생성된 30개의 부트스트랩 샘플을 가지는 랜덤포레스트 기반 보행 단계 추정 모델에 학습에 사용하지 않은 데이터를 이용하여 산출한 정확도를 정리한 표는 아래 표 4와 같다.

Table 4. Comparison of verification data accuracy and experiment data estimation accuracy (gait phase).

표 4. 검증 데이터 정확도와 실험 데이터 추정 정확도의 비교(보행단계)

Gait Phase	Validation data accuracy	Experiment data accuracy
Heel contact	97.8%	97.2%
Full contact	97.1%	96.3%
Toe off	97.3%	96.7%
Swing	99.6%	99.5%
Average	98.1%	97.4%

정확도 비교 결과 입각기의 경우 검증 데이터 정확도보다 실험 데이터의 정확도가 전체적으로 조금씩 낮아졌음을 확인할 수 있다. 이는 실험 데이터의 경우 학습 데이터 내 비슷한 유형의 데이터가 없어 정확도가 낮아진 것으로 판단된다. 검증 데이터와의 오차는 추가적으로 다양한 대상의 데이터를 가지고 추정 모델을 학습할 시 줄어들 것으로 예상된다. 또한 단계별로 약 3~4%씩 발생한 오차는 대부분 보행 단계가 전환되는 시점에서 발생한 것으로 이 부분을 보완한다면 정확도가 좀 더 상승할 것으로 예상된다.

나. 보행 환경 추정 정확도 비교

3절에서 생성된 30개의 부트스트랩 샘플을 가지는 랜덤포레스트 기반 보행 환경 추정 모델에 학습에 사용하지 않은 데이터를 이용하여 산출한 정확도를 정리한 표는 아래 표 5와 같다.

정확도 비교 결과 보행 단계 추정 모델보다 검증 데이터 정확도보다 실험 데이터의 정확도가 많이 낮아진 것을 확인할 수 있다. 이는 실험 데이터의

Table 5. Comparison of verification data accuracy and experiment data estimation accuracy (walking environment).

표 5. 검증 데이터 정확도와 실험 데이터 추정 정확도의 비교(보행환경)

Walking environment	Validation data accuracy	Experiment data accuracy
Upslope	90.1%	87.2%
Flat	91.3%	89.7%
Downslope	93.8%	91.1%
Average	91.7%	89.3%

경우 학습 데이터 내 비슷한 유형의 데이터가 없어 정확도가 낮아진 것으로 판단된다. 이 차이는 보행 단계 추정 모델과 동일하게 추가적으로 다양한 대상의 데이터를 가지고 추정 모델을 생성할 시 줄어들 것으로 예상된다.

III. 결론

본 논문에서는 대퇴의족의 자동 보행 모드 변경을 위하여 기존 개발된 알고리즘의 추정 한계점과 패턴 인식 기법의 급변하는 보행 환경에 대해서는 추정이 어려운 한계점을 해결하고자 머신러닝 기반 자동 보행 모드 변경 기법을 개발하였다.

제안하는 추정 기법은 무릎 각도와 관성센서를 이용하여 보행 한 걸음 내 특정 보행 단계에서 보행 환경을 추정하여 다음 걸음의 보행 모드를 자동으로 변경하는 것이다. 이를 위해서 보행 단계와 환경 추정 모델을 개발하였다. 의족 내 마이크로컨트롤러에 이식을 고려하여 랜덤포레스트를 이용하여 추정 모델을 생성하였다. 정상인이 의족 어댑터를 이용하여 무릎각도, 가속도 3축, 각속도 3축, 고관절 각도 3축 및 보행 단계, 환경이 레이블이 입력된 데이터 집합을 구축하였다.

랜덤포레스트 기반의 보행 단계 및 보행 환경 추정 모델을 생성하고 추정 정확도를 비교하였다. 비교 결과 검증 정확도가 97.4%인 보행 단계 추정 모델과 검증 정확도가 91.7%인 보행 환경 추정 모델이 가장 추정 성능이 좋음을 확인하였다.

두 모델을 의족 내의 마이크로컨트롤러에 이식하고 학습에 사용하지 않은 새로운 데이터를 모델의 입력 데이터로 주었을 때 보행 단계 추정은 평균 97.4%, 보행 환경 추정은 평균 89.3%의 추정 정확

도를 나타냄을 확인하였다.

본 논문에서 제안하고자 하는 추정 기법은 아직은 기존에 개발되었던 알고리즘에 비하여 추정 정확도가 다소 낮다. 하지만 향후 연구로써 제안하는 기법의 정확도 상승 방안에 대하여 연구하고자 하며 기존의 패턴 인식 또는 퍼지 추론 기법이 가지는 단점을 해결할 수 있을 것으로 판단한다.

References

- [1] Korea Employment Agency for the Disabled, Panel Survey of Employment for the Disabled: Characteristics by Disability Type, 2017. http://kosis.kr/statHtml/statHtml.do?orgId=383&tblId=DT_383003_P009
- [2] Chan, F. H., Yang, Y. S., Lam, F. K., Zhang, Y. T., & Parker, P. A., "Fuzzy EMG classification for prosthesis control," *IEEE transactions on rehabilitation engineering*, Vol.8, No.3, pp.305-311, 2000. DOI: 10.1109/86.867872
- [3] Spanias, J. A., Simon, A. M., Ingraham, K. A., & Hargrove, L. J., "Effect of additional mechanical sensor data on an EMG-based pattern recognition system for a powered leg prosthesis," *7th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp.639-642, 2015. DOI: 10.1109/NER.2015.7146704
- [4] L. J. Hargrove, A. M. Simon, A. J. Young, R. D. Lipschutz, S. B. Finucane, D. G. Smith, T. A. Kuiken, "Robotic leg control with EMG decoding in an amputee with nerve transfers," *New England Journal of Medicine*, Vol.369, No.13, pp.1237-1242, 2013. DOI: 10.1056/NEJMoA1300126
- [5] Sun-Jong Na, Jin-Woo Shin, Su-Hong Eom, Eung-Hyuk Lee, "A Study on the Activation of Femoral Prostheses: Focused on the Development of a Decision Tree based Gait Phase Identification Algorithm," *16th International Conference on Informatics in Control, Automation and Robotics (ICINCO)*, pp.775-780, 2019. DOI: 10.5220/0007950707750780
- [6] Shahmoradi, S., & Shouraki, S. B., "A Fuzzy sequential locomotion mode recognition system for lower limb prosthesis control," *Iranian Conference on Electrical Engineering (ICEE)*, pp.2153-2158, 2017. DOI: 10.1109/IranianCEE.2017.7985417
- [7] H. F. Maqbool, M. A. B. Husman, M. I. Awad, A. Abouhossein, Nadeem Iqbal, A. A. Dehghani-Sanij, "A Real-Time Gait Event Detection for Lower Limb Prosthesis Control and Evaluation," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.25, No.9, pp.1500-1509, 2017. DOI: 10.1109/TNSRE.2016.2636367
- [8] Simon, Ann M., Emily A. Seyforth, and Levi J. Hargrove., "Across-Day Lower Limb Pattern Recognition Performance of a Powered Knee-Ankle Prosthesis," *7th IEEE International Conference on Biomedical Robotics and Biomechanics (Biorob)*, pp.242-247, 2018. DOI: 10.1109/BIOROB.2018.8487836
- [9] Shahmoradi, S., & Shouraki, S. B., "A Fuzzy sequential locomotion mode recognition system for lower limb prosthesis control," *Iranian Conference on Electrical Engineering (ICEE)*, pp.2153-2158, 2017. DOI: 10.1109/IranianCEE.2017.7985417
- [10] H. F. Maqbool, M. A. B. Husman, M. I. Awad, A. Abouhossein, Nadeem Iqbal, A. A. Dehghani-Sanij, "A Real-Time Gait Event Detection for Lower Limb Prosthesis Control and Evaluation," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.25, No.9, pp.1500-1509, 2017. DOI: 10.1109/TNSRE.2016.2636367
- [11] Won ho Heo, Euntai Kim, Hyun Sub Park, and Jun-Young Jung, "A Gait Phase Classifier using a Recurrent Neural Network," *Journal of Institute of Control, Robotics and Systems*, Vol.21, No.6, pp.518-523. 2015. DOI: 10.5302/J.ICROS.2015.15.9024
- [12] Cho, Y. S., Jang, S. H., Cho, J. S., Kim, M. J., Lee, H. D., Lee, S. Y., & Moon, S. B., "Evaluation of Validity and Reliability of Inertial Measurement Unit-Based Gait Analysis Systems," *Annals of rehabilitation medicine*, Vol.42, No.6, pp.872-883, 2018. DOI: 10.5535/arm.2018.42.6.872
- [13] Jacquelin Perry, *Gait Analysis: Normal and Pathological Function, 2nd Edition*. SLACK

Incorporated, 2012.

DOI: 10.1302/0301-620X.92B8.0921184a

[14] Ledoux, E. D., "Inertial sensing for gait event detection and transfemoral prosthesis control strategy," *IEEE Transactions on Biomedical Engineering*, Vol.65, No.12, pp.2704-2712, 2018.

DOI: 10.1109/TBME.2018.2813999

[15] López-Delis, A., Miosso, C. J., Carvalho, J. L., da Rocha, A. F., & Borges, G. A., "Continuous Estimation Prediction of Knee Joint Angles Using Fusion of Electromyographic and Inertial Sensors for Active Transfemoral Leg Prostheses," *Advances in Data Science and Adaptive Analysis*, Vol.10, No.2, 2018. DOI: 10.1142/S2424922X18400089

[16] H. Wu, Q. Huang, D. Wang, and L. Gao, "A CNN-SVM combined model for pattern recognition of knee motion using mechanomyography signals," *Journal of Electromyography and Kinesiology*, Vol.42, pp.136-142, 2018.

DOI: 10.1016/j.jelekin.2018.07.005

[17] Ekkachai, K., & Nilkhamhang, I. "Swing phase control of semi-active prosthetic knee using neural network predictive control with particle swarm optimization," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.24, No.11, pp.1169-1178, 2016.

DOI: 10.1109/TNSRE.2016.2521686

[18] L. Breiman, "Random Forests," *Machine Learning*, Vol.45, pp.5-32, 2001.

DOI: 10.1023/A:1010933404324

[19] Segal, Ava D., et al. "Kinematic and kinetic comparisons of transfemoral amputee gait using C-Leg and Mauch SNS prosthetic knees," *Journal of Rehabilitation Research & Development*, Vol.43, No.7, pp.857-869, 2006.

DOI: 10.1682/JRRD.2005.09.0147

BIOGRAPHY

Sun Jong Na (Member)



2018 : BS degree in Biomedical Engineering, Konyang University
2018~ crrent : MS degree in Advanced Technology Fusion, Korea Polytechnic University

Jin-Woo Shin (Member)



2018 : BS degree in Electronics Engineering, Korea Polytechnic University
2018~ current : MS degree in Advanced Technology Fusion, Korea Polytechnic University

Su Hong Eom (Member)



2011 : MS degree in Information and Communications Engineering, Korea Polytechnic University
2017 : Ph.D degree in Information and Communications Engineering, Korea Polytechnic University
2017~crrent : Research Professor, Dept. of Electronics Engineering, Korea Polytechnic University

Eung-Hyuck Lee (Member)



1997 : Ph.D degree in Information and Communications Engineering, Inha University
2000~crrent : Professor, Dept. of Electronics Engineering, Korea Polytechnic University