

노면 적응형 대퇴 의족개발을 위한 발목 관절 부하 가변형 하퇴 의족 적용에 대한 연구

The Study on Applying Ankle Joint Load Variable Lower-Knee Prosthesis to Development of Terrain-Adaptive Above-Knee Prosthesis

엄수홍*, 나선종*, 류중현*, 박세훈**, 이응혁*

Su-Hong Eom*, Sun-Jong Na*, Jung-Hwun You*, Se-Hoon Park**, Eung-Hyuk Lee*

Abstract

This study is the method which is adapted to control ankle joint movement for resolving the problem of gait imbalance in intervals where gait environments are changed and slope walking, as applying terrain-adaptive technique to intelligent above-knee prosthesis. In this development of above-knee prosthesis, to classify the gait modes is essential. For distinguishing the stance phases and the swing phase depending on roads, a machine learning which combines decision tree and random forest from knee angle data and inertial sensor data, is proposed and adapted. By using this method, the ankle movement state of the prosthesis is controlled. This study verifies whether the problem is resolved through butterfly diagram.

요약

본 연구에서는 지능형 대퇴 의족의 노면 적응 기술 구현시 보행 환경이 변화하는 구간 및 약 경사로 보행에서의 보행 불평형 문제를 해결하기 위한 방법으로 발목 관절 운동을 제어 가능한 하퇴 의족을 적용하였다. 제안한 대퇴 의족의 개발을 위해서는 보행의 단계 구분이 필수적이다. 이러한 보행의 입각기의 단계별 구분과 유각기의 판단을 위하여 대퇴의족의 슬관절 데이터와 관성센서 데이터를 바탕으로 의사 결정 나무 학습법과 랜덤포레스트 기법을 융합한 머신러닝 기술을 제안 및 적용하였다. 이러한 방법으로 발목의 운동 상태를 제어 하였으며 보행 평형이 문제가 해소 되는지를 butterfly diagram을 측정하여 평가 하였다.

Key words : above-knee prosthesis, control ankle joint, decision tree, random forest, walking imbalance

* Dept. of Electronics Engineering, Korea Polytechnic University

**Korea Orthopedics & Rehabilitation Engineering Center

★ Corresponding author

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

※ Acknowledgment

This research was supported by the Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (NRF2017R1A2B2006958).

Manuscript received Sep. 5, 2019; revised Sep. 19, 2019; accepted Sep. 24, 2019.

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

2018년 고용노동부와 한국장애인고용공단 고용개발원의 보고서에 따르면 국내 장애인 수는 지속적으로 증가하고 있으며, 전체 장애인 중 지체 장애인의 수는 전체의 약 50%를 차지하고 있다[1]. 절단으로 인한 지체 장애인은 약 17.1%이며, 장애 부위는 46.3%로 하지 절단 장애인이 가장 많다[2]. 하지 절단은 절단 부위에 따라 족부절단, 하퇴절단, 슬관절 이단, 대퇴 절단 등으로 나눌 수 있다. 그 중 대퇴절단 환자의 경우 다른 하지 절단 유형대비 하지의 잔존 영역이 적어 보행에 제약이 가장 크다[3]. 대퇴 절단 환자들의 보행을 지원하기 위한 보조기기 중 신체 기능 복원을 목적으로는 대퇴의족이 있다. 1990년대 대퇴의족의 목적은 보행을 가능하도록 하는 것으로 별도의 편의사항이 없었다. 그렇기 때문에 그들은 의족 보행 다리가 건강한 다리보다 평균 60%이상의 신체 에너지 소모를 하며 보행하는 불편함이 있다[4]. 따라서 2000년대 이후는 그들의 삶의 질 향상을 위하여 다양한 환경에 대응하며, 보다 보행의 편리성을 추구 하는 지능형 대퇴 의족으로 연구 개발 되고 있는 실정이다[5-6].

현재의 지능형 대퇴 의족은 액추에이터에서 파워를 보조하는 유무에 따라 Semi-Active Microprocessor-Knee와 Powered-Knee로 구분된다. Microprocessor-Knee는 대표적으로 Ottobock사의 Genium, Ossur사의 Rheo Knee 등이 있다. 이러한 의족은 슬관절의 운동을 기계적 실린더 형태로 움직이지만 Microprocessor를 활용하여 실린더 운동의 저항력을 가변 제어 한다. 그렇기 때문에 기존의 수동적 관절의 의족 대비 더 적은 힘으로 보행을 할 수 있도록 지원하는 의족이다.

그러나 Microprocessor-Knee도 슬관절을 움직이는 구조가 기계식이기 때문에 인간의 관절과 같이 자유로운 각도 변화에는 한계가 있다. 이러한 단점을 개선하기 위하여 Powered-Knee는 슬관절의 운동을 전기모터를 사용하여 해결하고자 한다.

이러한 Powered-Knee는 액추에이터의 정밀 제어가 가능하기 때문에 다양한 보행 환경에 따라 보행 모드가 가변하며, 해당 보행 환경에 최적화된 보행 궤적을 구사가 가능하다. 현재 까지 연구된 보행 모드 변경 방법은 사용자가 외부의 리모트 디바이스를 조작하여 변경하는 방법, 생체 신호(EMG)

를 활용한 방법들이 연구 되었다[7-8].

그러나 이러한 방식은 사용자가 직접 보행 노면을 파악하고 모드를 변경해야 하는 불편함, 사용자의 조작 실수 또는 생체신호의 품질 문제로 인한 오작동을 유발 할 수 있는 여지가 있으며 의족의 오작동은 낙상을 유발하는 큰 위험이다.

따라서 이러한 문제를 개선하고자 최근 지능형 대퇴의족에 다양한 센서 탑재하고 여기서 수집되는 데이터를 바탕으로 사용자의 보행 의도나 현재 보행 중인 노면을 파악하고 그에 따른 보행 궤적을 만들어주는 자동 보행모드 전환 방식이 다양하게 연구되고 있다[9], [10].

그러나 현재 이러한 연구형태로 보행의 모드가 즉각으로 변화 되는 것은 아니며, 평지에서 경사도 진입하는 변화 구간 및 낮은 경사로에서는 특별한 대응을 못하는 실정이다. 그렇기 때문에 평지 보행과 동일하게 구현 되는 보행 궤적 때문에 수동 의족에서 발생하는 환측의 보폭 짧음으로 비롯되는 보행 불평형을 유발하게 된다[11].

이러한 보행이 장시간 유지될 경우 의족 착용자의 보행 리듬이 저하가 되며 최악의 경우 보행의 꼬임 또는 낙상을 유발하는 요인이 된다[12].

따라서 본 논문은 이러한 문제점을 해결하기 위하여 발목 관절에 가변 유압 실린더를 이용한 하퇴 의족을 적용하여 즉각적인 보행 모드 변화가 이루어지지 못하여 발생하는 부분을 발목관절의 변화로 보행 불평형을 보상 하고자 한다.

본 논문에서 제안하는 발목관절의 움직임 변화는 보행의 주기에서 초기 접지기부터 중간 입각기까지만 이루어 져야 하며 말기 입각기 부터는 고정되어 지면을 딛고 유각기에 진입하기 위한 보행 추진력을 만들 수 있도록 해야 한다. 따라서 발목이 고정되는 시점을 명확하게 구분해야 하는 전제조건이 따른다.

현재 보행의 단계를 구분하는 방법은 지면반발력을 이용하는 방법, 슬관절의 운동에 따른 궤적으로 구분하는 형태가 연구되었다. 이러한 연구는 보행자의 보행 패턴에서 비롯되는 특징을 기반으로 수행된다. 그러나 이러한 방법은 보행 환경이 뚜렷한 구분이 되어야 인식률이 높은 한계가 있으며, 정확한 패턴 인식을 위해 다수의 걸음으로 비롯된 데이터가 필요하다.

따라서 본 논문에서는 모호한 보행 환경에서 빠

른 보행 단계 구분을 위하여 머신러닝 기반의 보행 단계 분류 모델을 제안한다. 현재 머신러닝을 활용한 보행 단계 분류의 유사 연구로는 H. F. Maqbool 외 5명은 의족의 정강이 부분에 부착한 자이로스코프 센서를 이용하여 휴리스틱 기반의 알고리즘을 개발, 초기접지기와 Toe-off를 100%로 구분하였다[13]. Heo 외 3명은 입력층이 5개, 은닉 노드가 20개인 은닉 층 1개, 출력층 1개로 이루어진 순환형 신경망에 무릎각도와 양쪽 고관절에 부착한 관성센서 데이터를 이용하여 초기 접지기와 Toe-off를 구분하였다[14]. 그러나 선행 연구들의 방법으로는 세분화된 보행단계를 구분 하는 데에는 한계가 있다.

그렇기 때문에 본 논문에서는 부하 반응기부터 중간 입각기를 구분하기 위하여 머신러닝의 기법 중 'IF~THEN'형식의 의사결정트리와 독립된 여러 의사결정트리의 집합인 랜덤포레스트를 융합한 머신러닝 기법을 제안 한다. 제안한 머신러닝 기법에 활용되는 데이터는 대퇴의족의 슬관절 무릎각도와 관성센서 에서 비롯되는 3축 가속도, 3축 자이로 데이터를 기반으로 수행한다.

이러한 제안방법으로 보행의 단계 판별이 명확하게 수행되는 지에 대한 평가는 학습하고자 하는 데이터를 5개로 나누어 4개의 fold로 훈련 후, 1개의 fold를 이용하여 검증하며 교대로 역할을 바꿔 5개의 검증 정확도의 평균을 사용하여 기존의 검증 방법보다 정확한 5-fold 교차 검증 기법을 활용하여 평가하며, 발목 관절의 운동을 조절하여 보행환경 변화 시작 구간 및 약 경사에서 적응형 보행이 달성 되어 보행 불평형 현상이 해소 되는 지에 대한 평가는 평지와 경사로에서의 발목 운동 변화시점을 발목관절 변화를 측정 하여 평가하고 이와 더불어 건축과 환측간의 butterfly diagram을 측정하여 평가 한다.

II. 본론

본 논문에서 발목의 운동을 제어하기 위한 시점은 그림 1과 같이 보행의 주기중 약 20%에 해당하는 구간이다. 그래프를 보면 정상인 다리의 슬관절 보행 궤적은 부하 반응기에서 신체의 체중심 변화로 인한 변곡점이 발생하는 특징이 있다. 그러나 기계식 관절을 갖는 의족의 보행은 해당 보행 주기에서 유의미한 특징을 찾기가 쉽지 않다. 따라서

본 논문에서는 머신러닝 기법을 활용한 방법을 제안하고자 한다.

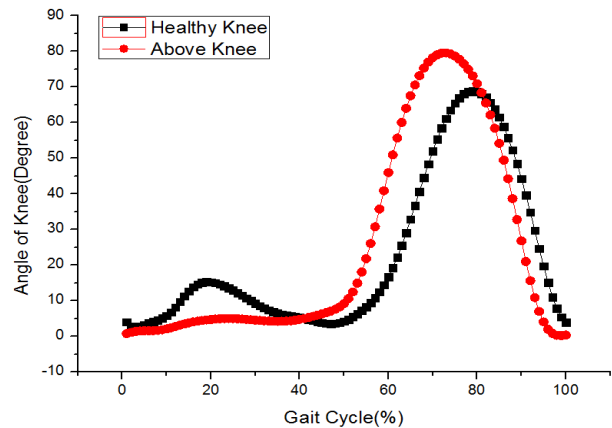


Fig. 1. The trajectory of a gait cycle of the prosthesis and normal.

그림 1. 의족 및 정상다리의 보행 한주기 궤적

제안하는 머신러닝 기법의 학습기는 의사결정트리와 1차적으로 수행 후 2차적으로 랜덤포레스트 기법을 적용 한다. 다양한 머신러닝 학습 알고리즘 중 의사결정트리를 사용하는 이유는 보행의 시퀀스가 순차별 단계 발생의 명세인 상태머신의 동작으로 해석되기 때문이며, 향후 임베디드 시스템으로 적용시 이식성을 고려했기 때문이다.

1. 머신러닝 기법을 활용한 보행 단계 판별 기법

본 논문에서 목표로 하는 보행 단계 구분은 의족의 슬관절 변화에 따른 데이터를 바탕으로 보행단계를 분류를 수행하여야 한다. 이는 입력데이터를 기반으로 이에 대한 출력의 상태를 도출하는 형태로 머신러닝 기법 중 지도학습에 의한 학습이 가장 적절하다고 판단된다. 이 같은 이유는 비지도 학습은 비분류 데이터를 이용한 분류에 적합하고, 강화 학습은 현재 상태의 관찰과 행동 후 얻을 수 있는 보상에 따라 차등을 두어 최적의 행동을 스스로 학습하는 분류에 적합하기 때문이다[15-16].

현재 지도 학습으로 활용되는 알고리즘은 SVM (Support Vector Machine), 인공신경망(Artificial Neural Network), 의사결정트리 등이 대표적이다.

SVM은 각 그룹에서 데이터 간의 거리를 측정하고 중심을 구한 후, 그 가운데에서 최적의 초평면(Hyperplane)을 구해 분류한다[17]. 위에서 제시한 세 가지 지도 학습 중 가장 높은 분류 정확도를 가

지만 데이터의 전처리와 매개변수의 설정에 따라 정확도가 달라진다. 또한 샘플이 많을수록 속도가 느려지고 메모리를 많이 소비하여 PC를 이용하여 시뮬레이션은 가능하지만 장치 내의 마이크로컨트롤러에 적용하기에는 어렵다.

인공신경망(ANN)은 인간 두뇌의 정보 처리 과정을 모방한 것으로, 기존의 패턴인식 알고리즘으로 해결하지 못한 복잡한 문제를 해결할 수 있지만 연산량이 적지 않고 마이크로프로세서에 구현하기가 쉽지 않다[18].

의사결정트리는 학습하는데 시간이 비교적 짧고, 결과 값은 기존의 알고리즘에 사용하는 Threshold 기법과 유사하며, 단계적 분류를 수행하기 때문에 연속적인 상태에 따른 보행의 분류에 큰 어려움 없이 분류 가능하고, 또한 마이크로컨트롤러에서의 구현이 용이한 장점이 있다[19].

따라서 본 논문에서는 데이터 전처리 과정이 필요 없고 학습과 결과 값이 간단한 의사결정나무와 의사결정트리를 응용한 앙상블 기법인 랜덤 포레스트 기법을 융합한 보행 단계 판별 모델을 제안한다.

가. 의사결정트리

의사결정나무는 반복적으로 분류 모형을 생성하여 가장 효과적인 분류 모형을 나무의 형태로 만드는 기법이다. 모형을 구축하는데 소요되는 시간이 짧으며 분석에 대한 과정을 볼 수 있어 결과를 해석하고 이해하기 쉽다. 또한 데이터의 스케일 전환 없이 데이터를 그대로 사용해도 된다는 장점이 있다. 의사결정나무는 가지 생성 방법에 따라 여러 의사결정나무 방법론으로 나뉘며, 본 논문에서는 가장 보편적으로 사용되는 CART(Classification And Regression Tree)기법을 사용하고자 한다[20].

CART는 이진 분할을 통해 가지를 치며 분류 지점을 찾기 위해서 지니 계수(Gini index)를 사용한다. 지니 계수는 불순도(impurity)를 측정하는 지수로, 어떤 주어진 집합에서의 지니 계수는 다음과 같은 식 (1)으로 계산한다.

$$Gini = \sum_{i=1}^m p_i(1-p_i) \tag{1}$$

분류할 데이터셋은 m개의 클래스를 가지고 있으며 p_i 는 주어진 데이터셋 내의 각 클래스의 비율을 나타낸다. CART는 Gini Index가 작을수록 좋은

모델로 판단한다. Gini Index를 이용하여 CART가 부모 노드에서 자식 노드로 갈라지는 분리 지점을 찾아내는 식은 식 (2)와 같다.

$$\Delta Gini = Current\ Gini - (P_L \cdot Gini_L) + (P_R \cdot Gini_R) \tag{2}$$

Current Gini는 부모 노드의 지니 계수이다. P_L 과 P_R 은 부모 노드에서 갈라진 왼쪽과 오른쪽 자식 노드의 개수이며 $Gini_L$ 와 $Gini_R$ 은 부모 노드에서 갈라진 왼쪽과 오른쪽 자식 노드의 지니 계수이다. $\Delta Gini$ 는 분리 지점에 따른 지니계수로 반복 과정을 통해 가장 작은 지점을 찾는다.

이러한 과정을 통해 의사 결정 나무의 마디는 점점 증가하게 되며, 마디가 많아질수록 분류 정확도는 증가하게 된다. 분류 모델이 복잡해지고 학습 데이터에만 너무 잘 맞게 되어 학습에 사용되지 않은 새로운 데이터에 사용 시 분류 성능이 떨어지게 되는 과대적합이 발생할 가능성이 높아지게 된다.

따라서 본 논문에서는 불필요하게 성장된 자식 마디를 제거하여 의사결정나무를 단순화시키는 가지치기 기법을 통하여 과대적합을 예방하고자 한다.

나. 랜덤포레스트

랜덤포레스트는 여러 개의 분류모형에 의한 결과를 종합하여 분류 정확도를 높이는 앙상블(ensemble) 기법 중 하나다. 랜덤포레스트는 여러 개의 의사결정나무를 만들고 각각 분류모형의 결과의 평균값을 이용하기 때문에 분산을 감소시키고 데이터가 편향되는 것을 유지하여 의사결정나무에서 발생할 수 있는 과대적합을 예방한다.

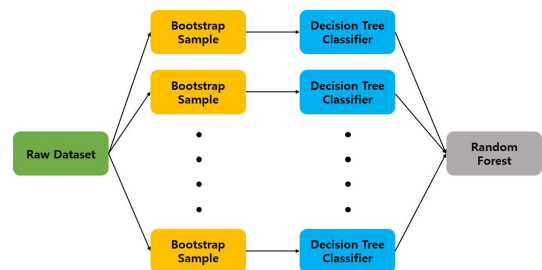


Fig. 2. Random Forest Block Diagram.

그림 2. 랜덤포레스트 블럭도

랜덤포레스트를 사용하기 위해서는 그림 2처럼 부트스트랩 샘플(Bootstrap sample)을 생성해주어야 한다. 원래의 데이터셋을 속성별로 나눈 후, 다시

데이터셋 크기에 맞게 나눠놓은 속성을 무작위로 추출하여 부트스트랩 샘플을 만든다. 이러한 방식을 반복추출 방식이라고 하며 하나의 부트스트랩 안에서는 같은 속성이 중복될 수 있으며, 누락되는 속성도 생길 수 있다. 따라서 각각의 부트스트랩을 통해 생성된 의사결정나무들은 서로 독립적이기 때문에 과대적합이 예방되어 새로운 데이터가 입력되어도 안정적으로 분류가 가능하다.

하나의 부트스트랩 샘플에서 반복추출 방식으로 인해 속성 하나가 부트스트랩 샘플에서 제외될 확률을 구하는 공식은 식 (3)과 같다.

$$\lim_{n \rightarrow \infty} (1 - \frac{1}{n})^n = e^{-1} = 0.3678 \quad (3)$$

랜덤포레스트는 전체 데이터셋에서 제외된 36.78%의 샘플들을 모아 검증데이터로써 생성된 모델의 성능을 평가하는 OOB(Out-of-Bag) error를 사용하여 정확도를 평가한다[21].

2. 의족 제어 방법

본 논문에서 제안하는 발목 가변 대퇴의족의 제어는 다음과 같다. 제어는 크게 두 단계로 구분된다. 첫 번째 제어는 입각기에서 중간 입각기를 검출하여 말기 입각기 전에 발목 가변을 고정하여 말기 입각기에서 보행 추진력을 얻을 수 있도록 한다. 두 번째 제어는 유각기에서 발목의 락을 해제 하여

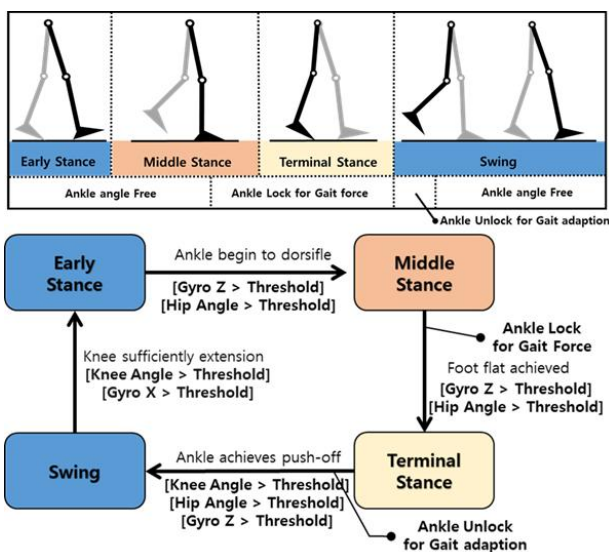


Fig. 3. The block diagram of transfemoral prosthesis based on the ankle joint variable.

그림 3. 발목 관절 가변 기반의 대퇴의족의 제어 블록도

초기 접지기와 중간 입각기간의 발목을 관성에 의하여 움직일 수 있도록 하는 것이다. 이같은 제어 시퀀스는 그림 3과 같다.

3. 구현 및 평가

가. 보행단계의 훈련 및 검증 결과

본 논문에서는 Passive 의족의 보행에서 관성 센서를 활용한 보행 단계 판별을 하기 위하여 의사결정 나무 학습법을 제안하였다. 따라서 학습을 위한 훈련 데이터 취득을 위하여 그림 4와 같이 정상인이 착용할 수 있는 소켓에 ottobock사의 3R60의 족을 부착하고 관절의 변화를 절대적으로 확인하기 위하여 정밀 소형 엔코더를 부착하여 관성센서 데이터와 함께 취득 하였다. 소형 엔코더는 오토닉스사의 제품으로 스펙은 360 pulses/revolution 이다. 관성센서는 x-io사의 NGIMU를 사용하였고 모든 데이터의 취득은 WiFi 통신으로 취득하였다. Passive 의족으로 3R60의족을 선택한 이유는 피험자 중 대퇴 의족 사용자의 의족과 동일한 실험조건으로 맞추기 위함이다.




Fig. 4. The flatfoot of transfemoral prosthesis for adapting proposed algorithm.

그림 4. 보행단계 훈련을 위한 데이터 취득 플랫폼

훈련 데이터는 건강한 20대의 체중 70kg남자 2명, 80kg남자 3명과 체중 72kg, Stump Length 44cm 오른쪽 수동 대퇴 의족 사용자로부터 취득 하였다.

실험 방법은 평지 보행에서 보폭 30cm, 지속 보행 5걸음으로 총 500회씩을 취득하고, 의사결정 나무를 이용하여 훈련하였으며 그림 5와 같은 의사결정 나무기반의 보행 단계 분류 모델과 표 1과 같은 Threshold를 얻을 수 있었다.




Fig. 5. the result of decision tree.

그림 5. 학습한 의사결정나무 결과

Table. 1. boundary values obtained in the learning according to gait phases.

표 1. 보행단계에 따른 학습 결과 Threshold

보행단계	Threshold
초기 접지기	GyroZ<-10.392 and hipangle<1.09251 and kneeangle>=0.432182 외 3개
중간 입각기	GyroZ<-10.392 and hipangle>=1.09251 and hipangle<-11.2027 외 1개
말기 입각기	GyroZ<-10.392 and hipangle>=1.09251 and hipangle<-11.2027 and Gyro X>=7.72385
유각기	GyroZ>=-10.392 and kneeangle>=-1.0925 and hipangle>=-3.47349 외 3개

취득된 데이터 중 의사결정나무의 요소로 사용된 값은 소형 엔코더로 취득한 슬관절 변화의 각도, 관성센서로 취득된 의족 착용 다리의 고관절 변화 각도, 의족 보행 방향의 각속도, 보행 진행시 발행되는 Yaw축의 각속도 이다.

취득된 데이터는 그림 6과 같다.

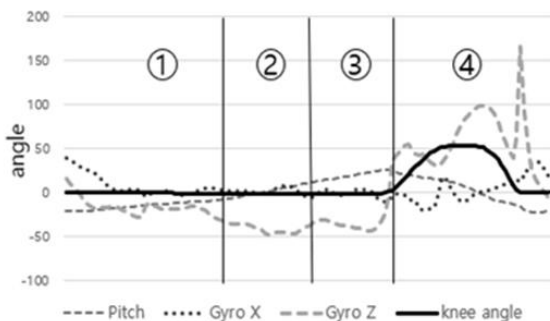


Fig. 6. the graph of a gait cycle in machine learning.

그림 6. 머신러닝 학습을 위한 보행의 한주기 그래프

그림 6의 그래프에서 knee angle은 유각기가 시작하는 부분에서 기울기가 급격하게 증가하며 hip

angle은 입각기에서부터 서서히 증가하며 유각기가 시작되는 부분부터 감소하기 시작한다. Gyro Z는 유각기에서 의족 진행방향의 Yaw축 움직임이다. Yaw축의 데이터 변화는 보행 중 골반이 움직이며 발생하는 운동량의 반영으로 해석 할 수 있다. 따라서 유각기에서 변화의 값이 크게 나타남을 확인 할 수 있다.

그러나 보행 진행 방향의 각속도인 Gyro X값은 취득된 데이터중 큰 변화량이 없기 때문에 의사 결정 나무에서 분류를 위해 사용한 요소인 knee angle, hip angle, Gyro Z간의 연관관계를 중점으로 랜덤 포레스트를 이용하여 학습 하였다. 학습 결과는 표 2와 같다.

Table. 2. Changes in the training, cross validation, and OOB error according to the number of bootstrap samples.

표 2. 부트스트랩 샘플의 개수에 따른 훈련, 교차 검증, OOB error값의 변화

name bootstrap	Training	Cross Validation	OOB error
5	38.5%	42.5%	36.7%
10	63.7%	65.4%	63.1%
20	92.3%	93.4%	91.9%
50	98.8%	96.4%	95.6%
100	99.0%	97.9%	96.7%
200	99.1%	98.1%	96.9%

부트스트랩 샘플의 개수가 많아짐에 따라 검증 정확도와 OOB error값이 증가하는 것을 확인할 수 있다. 또한 부트스트랩 샘플의 개수가 100개 이후는 학습시간과 학습에 소모하는 메모리에 비하여 정확도의 상승폭이 눈에 띄게 줄어드는 것을 확인할 수 있었다. 따라서 본 논문에서는 부트스트랩의 개수가 50개인 랜덤 포레스트 기반의 보행 단계 판별 모델을 이용하여 이후의 실험을 진행하고자 한다.

나. 발목 관절 변화형 대퇴의족의 적용

(1) 대퇴 의족 플랫폼

본 논문에서 사용한 의족은 국내 00연구소와 공동 연구한 의족으로 그림 7과 같다. 슬관절 range of motion은 0°~90°를 갖으며, 족관절 range of motion of 16° of plantar flexion and 18° of dorsiflexion를 갖는다. 무게는 Knee 2.1kg, Angle 1.4kg, 배터리

0.35kg, 제어기 0.15kg 으로 총합 4kg 이다. 슬관절의 동력은 BLDC모터로 100W출력을 갖는 maxon 사 EC 60 플랫 모터를 적용되었다. 모터의 감속 및 토크 증가를 위하여 하모닉 드라이브를 적용하였으며 기어비는 50:1 이다. 하퇴의족의 경우 유압 노즐을 제어할 위한 모터만 있고 Powered Assist 기능을 위한 모터는 없다.




Fig. 7. The flatform of above-knee prosthesis for adapting proposed algorithm.

그림 7. 제안한 알고리즘 적용을 위한 대퇴 의족 플랫폼

(2) 제안한 대퇴 의족의 제어기

주제어기는 그림 8과 같이 DSP 프로세서인 TI사의 TMS320F28335를 적용되었다.

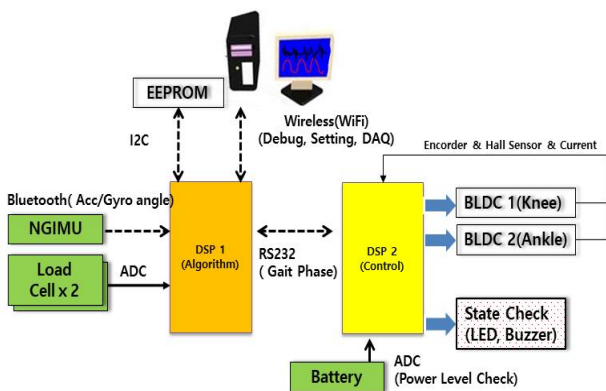


Fig. 8. The block diagram of a controller of proposed Above-Knee prosthesis.

그림 8. 제안한 대퇴 의족의 제어기 블록도

구동 클럭은 150MIPS이다. 프로세서는 슬관절 모터 및 하퇴의족의 관절 움직임 부하 조절용 모터 드라이브의 제어, 의족구동 알고리즘 및 본 논문에서 제안한 보행단계 판별 알고리즘의 연산을 각각 수행하도록 2개를 탑재되었다. 두 프로세스간의 데이터 통신은 TTL 레벨의 UART 통신을 하며, 관성센서 데이터의 취득은 블루투스로 수신 하였다.

라. 보행평형 달성의 평가

분류된 Stance Phase의 보행 단계를 바탕으로 발목을 가변 제어 하였을 때의 보행 평형 평가를 위하여 우선 적으로 발목의 가변 제어가 적절하게 이뤄지는지를 실험 하였다. 실험은 분류기에서 비롯된 제어 트리거 신호를 바탕으로 발목의 변화를 3차원 동작 분석기로 확인 하였다. 3차원 동작 분석시스템(Cortex 6.02, Motion Analysis Corp., USA)을 활용하여 확인 하였다. 해당 시스템은 12대의 적외선 카메라로 구성 되어 있으며 120Hz의 샘플링을 갖고 지름 12.5cm의 반사마커를 사용한다. 평가를 위한 실험은 정상적인 다리의 발목, 제안한 의족 시스템의 발목, 일반적인 수동 의족의 발목에 마커를 부착하여 발목의 변화를 측정 하여 발목의 변화인 plantar flexion과 dorsiflexion의 각도 변화를 관찰 하였다. 측정된 그래프는 그림 9과 같으며 발목의 적절한 변화만으로도 기존의 수동형 의족 보다 실제 건강한 발목의 보행에서 보여주는 궤적을 유사하게 나타남을 확인 하였다.

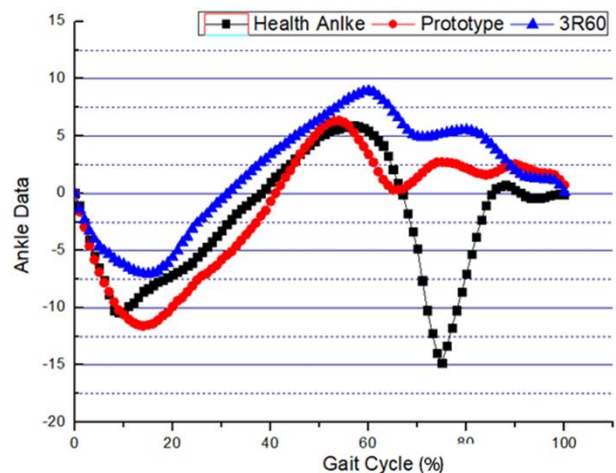


Fig. 9. Gait trajectory of Helthy Ankle, Variable (Non-Powered) Ankle and Fixed Ankle.

그림 9. 정상 발목, 제안한 방법으로 구현된 대퇴 의족 플랫폼의 발목, 보편적인 수동 의족 발목의 보행 궤적

이 같은 결과는 본 논문에서 달성하고자 하는 발목 가변의 제어가 기존의 대퇴의족 시스템에서 조금더 사용자의 보행 평형에 도움을 줄 수 있음을 확인 하였다.

두 번째 실험은 발목의 가변 제어가 보행시 어떻게 보행 불평형을 해소 가능한지의 실험을 하였다. 실험은 의족에서 보행시 발생하는 지면 반발력을 의족에 탑재된 로드셀의 Low Data가 1000값을 기준으로 발지 지면에서 닿고 떨어짐으로 설정하고 발목을 처음부터 고정된 상태, 유각기부터 중간 입각기까지는 가변상태를 두고 중간 입각기 이후는 고정된 상태, 모든 보행 주기간 가변상태를 유지한 상태 3가지 상황으로 지면 반발력의 차이 실험 하였다. 실험 결과는 그림 10와 같다. 발목을 고정 한 상태로 보행을 할 경우 Toe off 시점이 짧아지는 경향을 보이며 반대로 발목을 유연하게 하고 보행을 할 경우 Toe off 시점이 길어지는 것을 확인 할 수 있다 따라서 적절한 Toe off 시점이 보행 평형에 도움을 줄 수 있음을 확인 하였다.

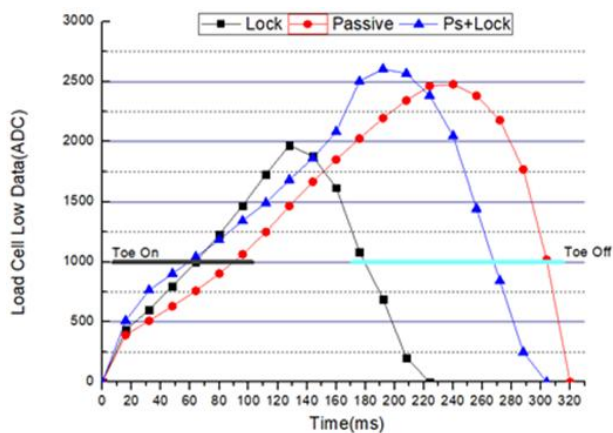


Fig. 10. The ground reaction difference and the contact point of foot in ground depending on ankle variable control.
 그림 10. 발목 가변 제어에 따른 지면반발력 차이 및 발의 지면 접촉 시점 그래프

마지막으로 실제 건축과 환측의 보행 평형 확인을 확인하기 위하여 Dynamic foot pressure examination 을 확인 하였다. 평가는 Zebris사의 Gait analysis 트레드밀을 이용하여 평가 하였다 보행 속도는 1.5km/h, 경사도는 Degree 4°이다. 평가 방법에서 평지가 아닌 약 경사인 이유는 서론에서 언급한 문제인 경사로 진입 구간에서의 보행 불 평형을 측정하기 위한 임의설정이다. 평가 그래프는 그림 11과

같다. 그래프를 보면 확연하게 발목이 고정된 3R80 Passive 의족대비 본 논문에서 제안한 발목 가변 하이브리드 대퇴 의족이 보행 평형을 보임을 확인 할 수 있다.

이 같은 이유는 보행시 발목 관절의 적절한 변화가 Passive의족으로 보행시 정상인의 Stance Phase 보행 궤적에서 발생 되는 부하반응기의 바운스 역할을 일부 보상 해주었기 때문이며 Swing Phase 에서 슬관절의 운동을 Powered Assist 해주었기 때문으로 볼 수 있다.

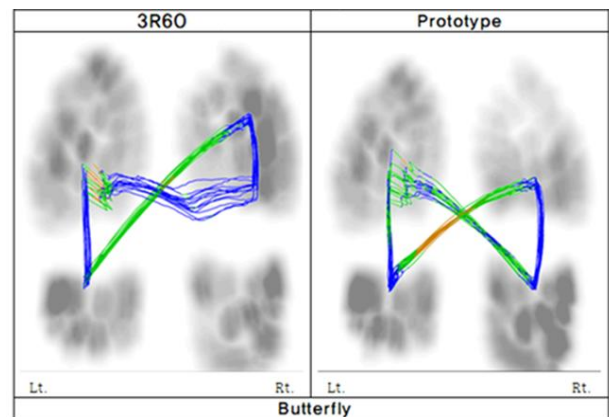


Fig. 11. Butterfly diagram of Existing prosthesis and Prosthesis with proposed techniques.

그림 11. 제안한 방법을 적용한 대퇴 의족과 일반적인 대퇴 의족의 보행 평형 평가를 위한 버터 플라이 다이어그램

III. 결론

본 논문에서는 국내 재활공학연구소에서 개발한 발목 관절의 운동 부하 조절 하퇴의족을 활용하여 대퇴의족에 적용시 기존의 의족 시스템에서 보행 환경이 변화 되는 구간 및 약 경사에서 발생하는 보행 불평형을 해소를 위한 연구를 수행하였다. 연구는 발목 관절의 가변 구간 시점 도출을 위하여 머신러닝 기술을 적용하였다. 적용 기술은 의사결정트리와 랜덤포레스트 기법을 융합한 방법을 사용하였으며 목표하는 발목의 제어 시점을 적절하게 검출 하였다. 그리고 제안한 방법을 실제 대퇴 의족에 적용하여 발목의 가변 제어가 보행 평형을 보임을 확인 하였다. 이 같은 연구 결과는 Powered 하퇴 의족을 사용하지 않았음에도 불구하고 지능형 대퇴 의족에서 보행평형을 달성 하여 이러한 보행제어 방법도 대퇴 의족 사용자의 사용 편리성을

항상 시킬 수 있음을 확인 하였다. 그러나 아직 연구의 초기 상태로 정량적인 발목 관절의 저항력 등의 제시가 부족하고 경사도가 높은 보행 환경에서의 추가적인 실험이 필요하다.

References

- [1] Ministry of Employment and Labor, 2018 Disabled Statistics, 2018.
- [2] 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=D T_383003_P009
- [3] Alcocer, W., Vela, L., Blanco, A., Gonzalez, J., and Oliver, M., "Major Trends in the Development of Ankle Rehabilitation Devices," *Int. J. DYNA*, Vol.79, No.176, pp.45-55, 2012. ISSN 0012-7353.
- [4] Quintero, D., Villarreal, D. J., & Gregg, R. D. "Preliminary experiments with a unified controller for a powered knee-ankle prosthetic leg across walking speeds," *In 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp.5427-5433, 2016.
DOI: 10.1109/IROS.2016.7759798
- [5] Su, B. Y., Wang, J., Liu, S. Q., Sheng, M., Jiang, J., & Xiang, K. "A CNN-Based Method for Intent Recognition Using Inertial Measurement Units and Intelligent Lower Limb Prosthesis," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol.27, no5, pp.1032-1042, 2019.
DOI: 10.1109/TNSRE.2019.2909585
- [6] Spanias, J. A., Simon, A. M., Finucane, S. B., Perreault, E. J., & Hargrove, L. J. "Online adaptive neural control of a robotic lower limb prosthesis," *Journal of neural engineering*, vol.15, no.1, 2016.
DOI: 10.1088/1741-2552/aa92a8
- [7] Brantley, J. A., Luu, T. P., Nakagome, S., & Contreras-Vidal, J. L. "Prediction of lower-limb joint kinematics from surface EMG during overground locomotion," *In 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 1705-1709, 2017.
DOI: 10.1109/SMC.2017.8122861
- [8] Afzal, T., Iqbal, K., White, G., & Wright, A. B. "A method for locomotion mode identification using muscle synergies," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol.25, no.6, pp.608-617, 2017.
DOI: 10.1109/TNSRE.2016.2585962
- [9] Quintero, D., Villarreal, D. J., Lambert, D. J., Kapp, S., & Gregg, R. D. "Continuous-phase control of a powered knee - ankle prosthesis: Amputee experiments across speeds and inclines," *IEEE Transactions on Robotics*, vol.34, no.3, pp.686-701, 2018. DOI: 10.1109/TRO.2018.2794536
- [10] Huang, H., Crouch, D. L., Liu, M., Sawicki, G. S., & Wang, D. "A cyber expert system for auto-tuning powered prosthesis impedance control parameters," *Annals of biomedical engineering*, vol.44, no.5, pp.1613-1624, 2016.
DOI: 10.1007/s10439-015-1464-7
- [11] Tao, W., Liu, T., Zheng, R., Feng, H. "Gait Analysis Using Wearable Sensors," *Sensors 2012*, vol.12, pp.2255 - 2283, 2012. DOI: 10.3390/s120202255
- [12] Rajčuková, V. a, Michalíková, M., Bednarčíková, L., Balogová, A., Živčák, J. "Biomechanics of Lower Limb Prostheses," *Procedia Engineering*, vol.96, pp.382-391, 2014.
DOI: 10.1016/j.proeng.2014.12.107
- [13] Maqbool, H. F., Husman, M. A. B., Awad, M. I., Abouhossein, A., Iqbal, N., & Dehghani-Sani, A. A. "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, 2016.
DOI: 10.1109/TNSRE.2016.2636367
- [14] 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
- [15] Vasan, G., & Pilarski, P. M. "Learning from demonstration: Teaching a myoelectric prosthesis with an intact limb via reinforcement learning,"

In 2017 International Conference on Rehabilitation Robotics (ICORR) pp. 1457–1464. 2017.

DOI: 10.1109/ICORR.2017.8009453

[16] Huang, Q., Yang, D., Jiang, L., Zhang, H., Liu, H., & Kotani, K. “A novel unsupervised adaptive learning method for long-term electromyography (EMG) pattern recognition,” *Sensors 2017*, vol.17, no.6, pp.1370, 2017. DOI: 10.3390/s17061370

[17] Wu, H., Huang, Q., Wang, D., & Gao, L. “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

[18] 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

[19] Liu, M., Wang, D., & Huang, H. H. “Development of an environment-aware locomotion mode recognition system for powered lower limb prostheses,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol.24, no.4, pp.434–443, 2015.

DOI: 10.1109/TNSRE.2015.2420539

[20] Wurdeman, S. R., Stevens, P. M., & Campbell, J. H. “Mobility Analysis of Amputees (MAAT 4): Classification tree analysis for probability of lower limb prosthesis user functional potential,” *Disability and Rehabilitation: Assistive Technology*, pp.1–8, 2019. DOI: 10.1080/17483107.2018.1555290

[21] Genuer, R., Poggi, J. M., Tuleau-Malot, C., & Villa-Vialaneix, N, “Random forests for big data,” *Big Data Research*, vol.9, pp.28–46, 2017.

DOI: 10.1016/j.bdr.2017.07.003

BIOGRAPHY

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~ current : Research Professor, Dept. of Electronics Engineering, Korea Polytechnic University

Sun Jong Na (Member)



2018 : BS degree in Biomedical Engineering, Konyang University

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

Jung Hwun You (Member)



2019 : BS degree in Energy & Electrical Engineering, Korea Polytechnic University

2019~current : MS degree in Advanced Technology Fusion, Korea Polytechnic University

Se Hoon Park (Member)



2000 : MS degree in Electronics Engineering, Kyongpook National University

2006 : Ph.D degree in Electronics Engineering, Kyongpook National University

2007~ current : Senior Research Engineer in Korea Orthopedics & Rehabilitation Engineering Center

Eung Hyuck Lee (Member)



1987 : MS degree in Information and Communications Engineering, Inha University

1997 : Ph.D degree in Information and Communications Engineering, Inha University

2000~current : Professor, Dept. of Electronics Engineering, Korea Polytechnic University