

Gait Type Classification Using Pressure Sensor of Smart Insole

Woo-Duk Seo*, Sung-Sin Lee**, Won-Yong Shin***, Sang-Il Choi****

Abstract

In this paper, we propose a gait type classification method based on pressure sensor which reflects various terrain and velocity variations. In order to obtain stable gait classification performance, we divide the whole gait data into several steps by detecting the swing phase, and normalize each step. Then, we extract robust features for both topographic variation and speed variation by using the Null-LDA(Null-Space Linear Discriminant Analysis) method. The experimental results show that the proposed method gives a good performance of gait type classification even though there is a change in the gait velocity and the terrain.

▶Keyword: Gait Type Classification, Smart Insole, Pressure Sensor, Discriminant Analysis, Classifier

I. Introduction

보행은 인간의 대표적인 동작들 가운데 하나로서, 보행 패턴의 분석은 생체공학, 재활의학, 헬스케어 등의 많은 응용분야에서 활용될 수 있다. 보행분석의 세부 분야의 하나로서 보행형태 분류는 센서를 사용해 취득한 보행데이터를 바탕으로 파킨슨씨 병 진단[1], 스포츠 분석[2], 노인 보행보조기구 개발[3]을 위해 연구되고 있다. 보행형태는 신체적 특성에 의한 물리적 차이, 속도 및 지형의 차이와 같은 요인에 쉽게 영향을 받는 특성을 가지고 있는데, 이러한 특성은 같은 보행형태 내에서의 변이를 크게 만들어 보행형태 분류의 성능에 악영향을 미친다. 이를테면, 같은 걸음 동작에 대해서도 평지를 걷는 것과 언덕길을 걷는 것의 패턴에 차이가 있고 이러한 변이는 '걸음'이라는 보행형태를 분류하기 위한 특징추출을 힘들게 한다.

보행형태 분류시스템은 센서데이터를 취득하는 센서 모듈과 취득된 데이터를 기반으로 분류결과를 계산하는 어플리케이션 모듈로 구성된다. 보행분류에 이용되는 센서로는 주로 비디오

센서[4], EMG(electromyographic)센서[5], plantar pressure 센서[6], 가속도센서[7, 8, 12], 자이로 센서[9, 10, 11] 등이 있다. 하지만 대부분의 센서들은 센서의 크기, 설치의 불편함과 같은 제약으로 인해 제한된 환경에서만 보행데이터를 측정할 수 밖에 없는 한계가 존재했다[6]. 최근 웨어러블 센서 기술의 발전은 보행데이터의 측정에 사용할 장비의 경량화 및 간소화를 이끌어내었다. 이러한 요인들에 기인해 장소 및 행동의 제약이 완화된 보행분류 연구가 활발히 진행되고 있으며, 스마트폰, 스마트 워치의 가속도센서, 자이로센서를 이용한 보행분류 연구가 많이 이루어지고 있다[7, 8, 9, 10, 11]. 최근 압력 센서를 부착한 스마트 깔창이 개발되어 가속도, 자이로[9, 10, 11] 뿐만 아니라 발바닥 표면의 정보를 이용하여 보행형태를 분류하는 연구도 시도되고 있다[31].

어플리케이션 모듈은 크게 전처리 단계, 특징추출단계, 분류단계의 세 단계로 나눌 수 있다. 전처리 단계에서는 수집된 데이터의

• First Author: Woo-Duk Seo, Corresponding Authors: Won-Yong Shin, Sang-Il Choi

*Woo-Duk Seo (genesis0717@gmail.com), Dept. of Data Science, Dankook University

**Sung-Sin Lee (leesungsin@gmail.com), Dept. of Data Science, Dankook University

***Won-Yong Shin (wyshin@dankook.ac.kr), Dept. of Computer Science and Engineering, Dankook University

****Sang-Il Choi (choisi@dankook.ac.kr), Dept. of Computer Science and Engineering, Dankook University

• Received: 2018. 01. 15, Revised: 2018. 01. 24, Accepted: 2018. 02. 05.

• This research was supported by the Human Resources Program in Energy Technology of the Korea Institute of Energy Technology Evaluation and Planning (KETEP) granted financial resource from the Ministry of Trade, Industry & Energy, Republic of Korea (no. 20174030201740) and also supported by the MIST(Ministry of Science and ICT), Korea, under the National Program for Excellence in SW supervised by the IITP(Institute for Information & communications Technology Promotion (no. IITP-2017-0-00091).

노이즈를 제거하고 분석에 적합한 형태로 데이터를 변환한다. 이를 위해, low-pass filter[12], 이동평균 필터(moving average filter)[13, 14], 다단계 웨이블릿 분해(multi level wavelet decomposition)[15, 16, 17]와 같은 노이즈 제거 필터와 걸음 단위를 정의하기 위해 영점교차검출(zero-crossing detection)[18, 19, 20, 21, 22], sliding window[23]와 같은 방법들이 사용된다. 특징추출단계는 데이터로부터 분류가 용이한 특징을 추출하는 단계로서, 다양한 종류의 선형 판별 분석 방법이나[24, 25, 26], 신경망[27]과 같은 기계학습 방법들이 사용될 수 있다. 분류단계에서는 K-최근접 이웃 분류기(K-nearest neighbor classifier), 지지벡터기계(support vector machine)[28]가 사용될 수 있다.

그동안 보행패턴 분류를 위한 여러 가지 방법들이 제안되어 왔다. Chen은 신발에 부착된 가속도 센서, 자이로 센서로부터 데이터를 취득한 후, 웨이블릿 분해를 적용한 특징을 사용하여 평지와 계단에서의 보행을 분류하는 분류기를 제안하였다[34]. [35]에서는 스마트 깔창의 압력 센서와 가속도센서, 자이로센서로부터 취득된 데이터의 평균, 최대, 최소, 상관계수와 같은 기술통계량을 특징으로 사용하여 평지, 계단, 언덕에서의 보행의 상태를 분류하는 분류기가 제안되었다. 압력 센서, 가속도센서, 자이로센서 모두를 사용할 경우, 분류의 정확도는 증가할 수 있지만 반면, 비용과 연속형 값을 사용하는 데에 따른 계산시간이 늘어나는 단점이 존재한다. 또한 기술통계량을 특징으로 사용하기 위해서는 충분한 크기의 보행데이터를 축적하는 것이 필요하며 이 역시 보행분류에 필요한 시간을 증가시키는 원인이 된다.

Peng은 스마트 깔창의 압력 센서로부터 취득된 보행데이터에 kernel PCA(kernel principal component analysis)[29]와 SVM(support vector machine)을 적용하여 계단, 평지에서의 보행 형태를 분류하는 분류기를 제안하였다[32]. 그러나 PCA는 데이터의 공분산 행렬(covariance matrix)의 분산이 최대화되는 방향으로 데이터를 사영하는 방법으로 원치 않는 변이까지 반영하게 되므로 다양한 변이가 존재하는 데이터를 분류하는 문제에 적합하지 않다는 한계를 가지고 있다[25].

본 논문에서는 압력 센서만을 이용하여 다양한 변이가 존재하는 보행데이터의 형태를 분류하는 보행분류 방법을 제안한다. 보행데이터의 취득을 위한 압력 센서로는 3L-Labs Co., Ltd.(Seoul Korea)에서 개발한 상용 스마트 깔창인 FootLogger를 사용하였다. FootLogger는 하나의 깔창에 8개의 압력 센서가 있으며 각각의 센서는 압력의 세기에 따라 0, 1, 2의 값을 저장한다. 본 논문에서는 걸음속도 변이, 지형 변이가 큰 보행데이터를 수집하기 위해 13인으로부터 8 종류의 보행형태, 즉 평지에서 걷기(WK), 빠른 걷기(FWK), 달리기(RUN), 언덕 올라가기(RA)와 내려가기(RD), 계단 올라가기(SA), 내려가기(SD)에 대한 데이터를 수집하였다. 제안한 보행분류기는 데이터의 노이즈를 제거하고 단위 걸음으로 분할하여 단위 걸음 샘플을 구성하는 전처리 단계, 데이터 샘플들로부터 분류에 유용한 특징을 추출하는 특징추출 단계, 그리고 추출된 특징을 이용한 분류 단계의 3가지로 구성 되어 있다. 전처리 단

계에서는 먼저 발이 공중에 떠 있는 상태인 Swing phase 검출을 통해 전체 데이터에서 한 걸음에 해당하는 구간을 정의하고, 각 단위 걸음에 대한 데이터를 분할한다. 그런 다음 걸음속도에 따른 데이터의 변이를 제거하고 단위 보행데이터 간의 동등한 비교를 위해 데이터 리사이징(resizing)을 수행하여 분할된 데이터의 길이가 모두 같도록 데이터를 정규화(normalize)[40]하였다. 특징 추출단계에서 Null-LDA(null-space linear discriminant analysis)[30]방법을 이용하여 정규화된 데이터로부터 판별 특징들을 추출 하였다.

제안한 방법은 압력 센서로부터 얻은 데이터만으로도 가속도, 자이로, 압력 센서 모두를 사용한 분류기에 상응할 정도의 우수한 분류성능을 보여 주었을 뿐 아니라 이산형 값을 사용하기 때문에 연속형 값을 사용할 때보다 계산량의 측면에서도 더 효과적인 장점이 있다.

본 논문의 구성은 다음과 같다. 2장에서는 다양한 센서들을 이용한 기존의 보행형태 분류 방법들을 소개한다. 3장에서는 제안한 단위 걸음 샘플을 구성하는 방법 및 판별 특징 추출에 의한 보행분류 방법을 설명한다. 4장에서는 제안한 보행분류 방법에 대한 실험과 결과를 설명하고 5장에서 결론을 맺는다.

II. Preliminaries

1. Gait Type Classifier Using Pression Sensors




Fig. 1. Gait type classification system using pressure sensor

[32]에서 Peng은 압력 센서만을 이용하여 보행형태를 분류하는 방법을 제안하였다(Fig. 1). 보행형태 분류를 위해 먼저 압력 센서로부터 얻은 데이터에 low-pass filter를 적용하여 노이즈를 제거한 후, 200ms 간격으로 신호를 분할 하였다. 그런 다음, kernel-PCA를 적용하여 데이터의 특징을 추출한 후 SVM[28]을 이용하여 보행형태를 분류하였다.

Kernel-PCA는 주성분 분석의 변형된 방법(PCA variant)로서, 비선형적으로 분포한 데이터로부터의 특징 추출이나 노이즈제거(denoising), 회귀의 전처리(pre-processing of regression) 등에 널리 사용된다[29]. Kernel-PCA는 특징 추출을 위해 먼저 커널 함수를 이용하여 입력 데이터를 고차원 공간으로 변환 한다. 그 후, 고차원 공간에서 데이터의 분산이 최대가 되도록 하는 사영벡터

를 찾아 특징 공간의 기저로 사용한다. n 차원의 N 개의 입력데이터 샘플 $\mathbf{x}_k \in R^n$, ($k=1, \dots, N$)에 대해, 커널 함수를 사용해 변환된 고차원 공간에서의 산포행렬과 kernel-PCA의 목적함수는 다음과 같이 정의된다.

$$S_T = \frac{1}{N} \sum_{i=1}^N \Phi(X_i) \Phi(X_i)^T \quad (1)$$

$$W = \operatorname{argmax}_W |W^T S_T W| \quad (2)$$

주어진 목적함수의 해는 고유값 분해[33]를 이용해 구할 수 있으며, S_T 의 n 번째 고유값 λ_n 및 고유벡터 \mathbf{w}_n 는 다음과 같이 표현된다.

$$\lambda_n \mathbf{w}_n = S_T \mathbf{w}_n \quad (3)$$

특징공간을 구성하는 사영벡터는 S_T 의 고유벡터들 중에서 고유값이 큰 순서대로 m 개를 선택하여 사용하며, 입력데이터 \mathbf{x}_k 는 사영벡터들로 구성된 사영행렬 W 에 의해 다음과 같은 특징벡터(\mathbf{y}_k)로 표현된다.

$$\mathbf{y}_k = W^T \Phi(\mathbf{x}_k) \quad (4)$$

이렇게 추출된 특징은 SVM[28]은 비선형적으로 분포한 데이터의 분류에 강점을 가지는 분류기로서, 특징 공간에서 마진(margin)이 가장 큰 초평면(hyper-plane)을 찾아 결정경계로 사용한다.

2. Gait Type Classifier Using Acceleration and Gyro Sensors




Fig. 2. Gait type classification system using acceleration and gyro sensors

Chen은 [34]에서 가속도 센서와 자이로 센서를 이용하여 평지에서의 보행과 계단에서의 보행을 분류하였다(Fig. 2). 이 방법은 보행 도중 발생하는 속도 변이를 제거하기 위해 피크점 검출을 사용하여 단위걸음신호를 분할한 후, 이산 웨이블릿 변환(discrete wavelet transform)을 사용하여 보행패턴의 특징을 추출하였다. 이산 웨이블릿 변환은 식(5)와 같이 근사정보(approximation information) $a_j(k)$ 와 상세정보(detail information) $d_j(k)$ 로 표현되는데, 여기서 $\phi_{j,k}(t)$ 와 $\psi_{k,j}(t)$ 는 각각 스케일링 함수(scaling function)와 웨이블릿 함수(wavelet function)를 의미하며 J 는 각각 분해를 수행한 단계, k 는 신호가 시간 축에서 이동한 정도를 의미한다.

$$f(t) = \sum_{k \in Z} a_j(k) \phi_{j,k}(t) + \sum_{k \geq 0} \sum_{j=1}^J d_j(k) \psi_{k,j}(t) \quad (5)$$

6레벨 이산 웨이블릿 변환을 통해 1개의 근사 계수

(approximation coefficient)와 6개의 상세 계수(detail coefficient)가 추출된다. 그 후, 각 계수들의 제곱합 평균을 특징으로 사용하였다. 특징벡터 T^i 와 원소 E^i, E^j 는 다음과 같다.

n_0 는 근사계수의 개수를 의미하며, n_j 는 j 번째 분해단계에서의 상세계수의 개수, i 는 센서의 인덱스를 의미한다. 분류기는 퍼지 논리 분류기를 사용하며 특징벡터의 각 원소를 분류함수에 넣은 값들을 바탕으로 보행형태를 분류한다. 상술한 알고리즘은 평지, 계단에서 측정된 보행형태에 대하여 약 92%의 높은 분류율을 보이지만, 피크 검출에서 많은 계산을 필요로 하며, 시간 변이가 큰 보행형태의 경우 안정적인 피크 검출이 어려우므로 다양한 보행형태 분류에 적용할 수 없다는 한계를 지니고 있다. Fig. 3과 Fig. 4는 각각 이산 웨이블릿 변환 분해과정의 흐름도와 가속도, 자이로를 이용한 보행 분류기의 센서 구성도이다.



Fig. 3. Flow chart of discrete wavelet transform decomposition process




Fig. 4. Configuration diagram of gait type classifier using acceleration and gyro sensor

3. Gait Type Classifier Using Pressure, Acceleration and Gyro Sensors

[35]에서 Chen은 가속도 센서, 자이로 센서, 압력 센서를 이용하는 보행분류기를 제안하였다. Chen의 분류기는 보행의 한 단위를 'Double Stance1', 'Single Stance', 'Double Stance2', 'Swing Phase'의 4단계로 나누고, 각 단계 별로 특징 선택 (feature selection) 방법을 적용하여 각 보행 단계에 최적화된 특징과 분류기를 선택하였다. Fig. 5은 가속도, 자이로, 압력 센서로 구성된 보행 분류기를 보여준다.

보행 분류를 위한 특징으로는 각 센서들의 평균, 최대, 최소, 상관계수와 같은 기술통계량을 사용하였으며, 분류기로는 선형판별분석방법, 이차판별분석(Quadratic Discriminant Analysis), 로지스틱회귀 방법을 사용하였다. 그러나 이 방법은 Phase 별로 최적화 된 모델의 사용을 가정하고 있어 phase가 정확하게 검출된 경우에는 89%에서 98%대의 높은 분류율을 보이지만 phase 검출의 오류에 취약한 단점이 있고, 새로운 형태의 보행학습 시 특징 선택 방법의 사용을 인해 오랜 시간이 걸린다는 한계를 지니고 있다. Fig. 6은 Chen이 제안한 보행 분류기의 학습 흐름도이다.




Fig. 5. Gait type classification system using pressure, acceleration and gyro sensors

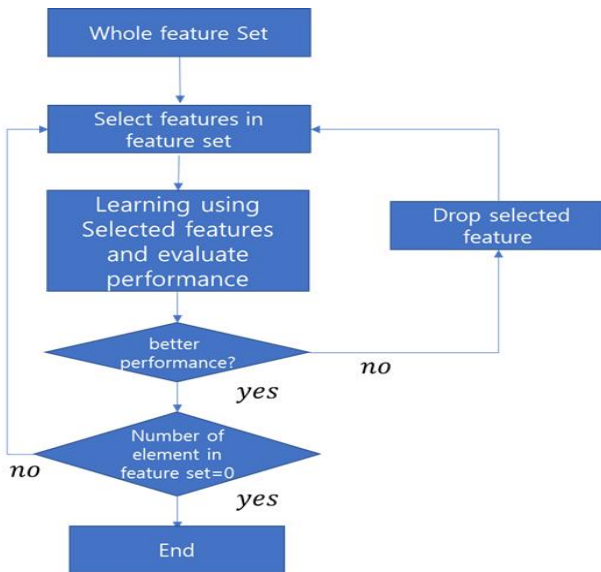


Fig. 6. Flow chart of training process using pressure, acceleration and gyro sensors for gait type classification

III. The Proposed Scheme

1. Definition of Unit Gait Sample




Fig. 7. Gait cycle of seven steps

Fig. 7에서와 같이, 보행주기(gait cycle)는 일반적으로 heel strike, foot flat, mid stance, heel off, toe off, mid swing, late swing의 7개 단계로 나뉜다[40]. Heel strike는 보행주기의 시작으로서, 발뒤꿈치가 지면과 만나는 상태, foot flat은 발바닥 전체가 바닥에 닿은 상태, mid stance는 몸의 중심이 앞발로 이동할 때까지의 상태, heel off와 toe off는 발뒤꿈치와 발끝이 지면에서 떨어지는 상태, mid swing과 late swing은 모두 발이 공중에 떠

있는 상태이며 late swing에서 하나의 보행주기가 끝난다. 또한 하나의 보행주기는 한 발이 떠 있는 상태인 swing phase와 땅에 붙어있는 상태인 stance phase로 분류할 수도 있다.

기준에 사용된 보행분류기들은 빠른 보행분류를 위해 sliding window 방법[32, 35]을 사용하였다. 하지만 같은 형태의 보행이라 할지라도 사람에 따라 또는 상황에 따라 조금씩 보행 속도의 차이가 있을 수 있고 이러한 보행 패턴의 변이는 수집된 데이터로부터 보행의 형태를 파악하는데 어려움을 초래한다. 이에 본 논문에서는 [31]에서 제안된 방법을 사용하여, swing phase를 검출하고 이를 바탕으로, 측정된 전체 걸음 데이터에서 단위 걸음 별로 보행 샘플을 구성하였다. 먼저 전체 걸음 데이터로부터 swing phase를 검출하였다. 기준은 다음과 같다.

Fig. 8는 FootLogger 깔창의 압력 센서를 이용하여 측정된 데이터의 일부를 보여주고 있다. FootLogger는 8개의 압력 센서를 갖고 있으며 각 센서는 100Hz의 샘플링율로 데이터를 측정한다. 압력 센서의 경우, 압력의 세기에 따라 0, 1, 2의 값으로 저장된다. 0은 압력이 없는 상태(발이 지면에서 떨어진 상태), 1은 약한 압력이 있는 상태, 2는 강한 압력이 있는 상태이다. Fig. 8에서 가로축은 각 센서의 인덱스를 의미하고 세로축은 0.01초 간격의 샘플링 포인트를 의미한다.

시간	센서1	센서2	센서3	센서4	센서5	센서6	센서7	센서8
2017-07-31 17:39:28.748	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.758	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.768	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.778	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.788	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.798	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.808	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.818	0	0	0	2	0	0	0	2
2017-07-31 17:39:28.828	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.838	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.848	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.858	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.868	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.878	0	0	0	2	0	0	1	2
2017-07-31 17:39:28.888	1	1	0	2	1	0	0	2
2017-07-31 17:39:28.898	1	1	0	2	1	0	0	2
2017-07-31 17:39:28.908	1	1	0	2	1	0	0	2
2017-07-31 17:39:28.918	2	2	0	2	1	0	0	2
2017-07-31 17:39:28.928	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.938	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.948	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.958	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.968	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.978	2	2	0	1	1	0	0	1
2017-07-31 17:39:28.988	2	2	0	1	1	0	0	0
2017-07-31 17:39:28.998	2	2	0	1	1	0	0	0
2017-07-31 17:39:29.008	2	2	0	0	1	0	0	0
2017-07-31 17:39:29.018	2	2	0	0	1	0	0	0
2017-07-31 17:39:29.018	2	2	0	0	1	0	0	0

Fig. 8. Example of measurement for gait pattern using FootLogger

$$\begin{cases} SWING & \text{if } p = 0 \\ STANCE & \text{if } p > 0 \end{cases} \quad (6)$$

$$p = \sum_{i=1}^8 (\text{value of } i\text{-th pressure sensor})$$

Swing phase에서의 샘플링 포인트에서는 발이 지면에서 떨어

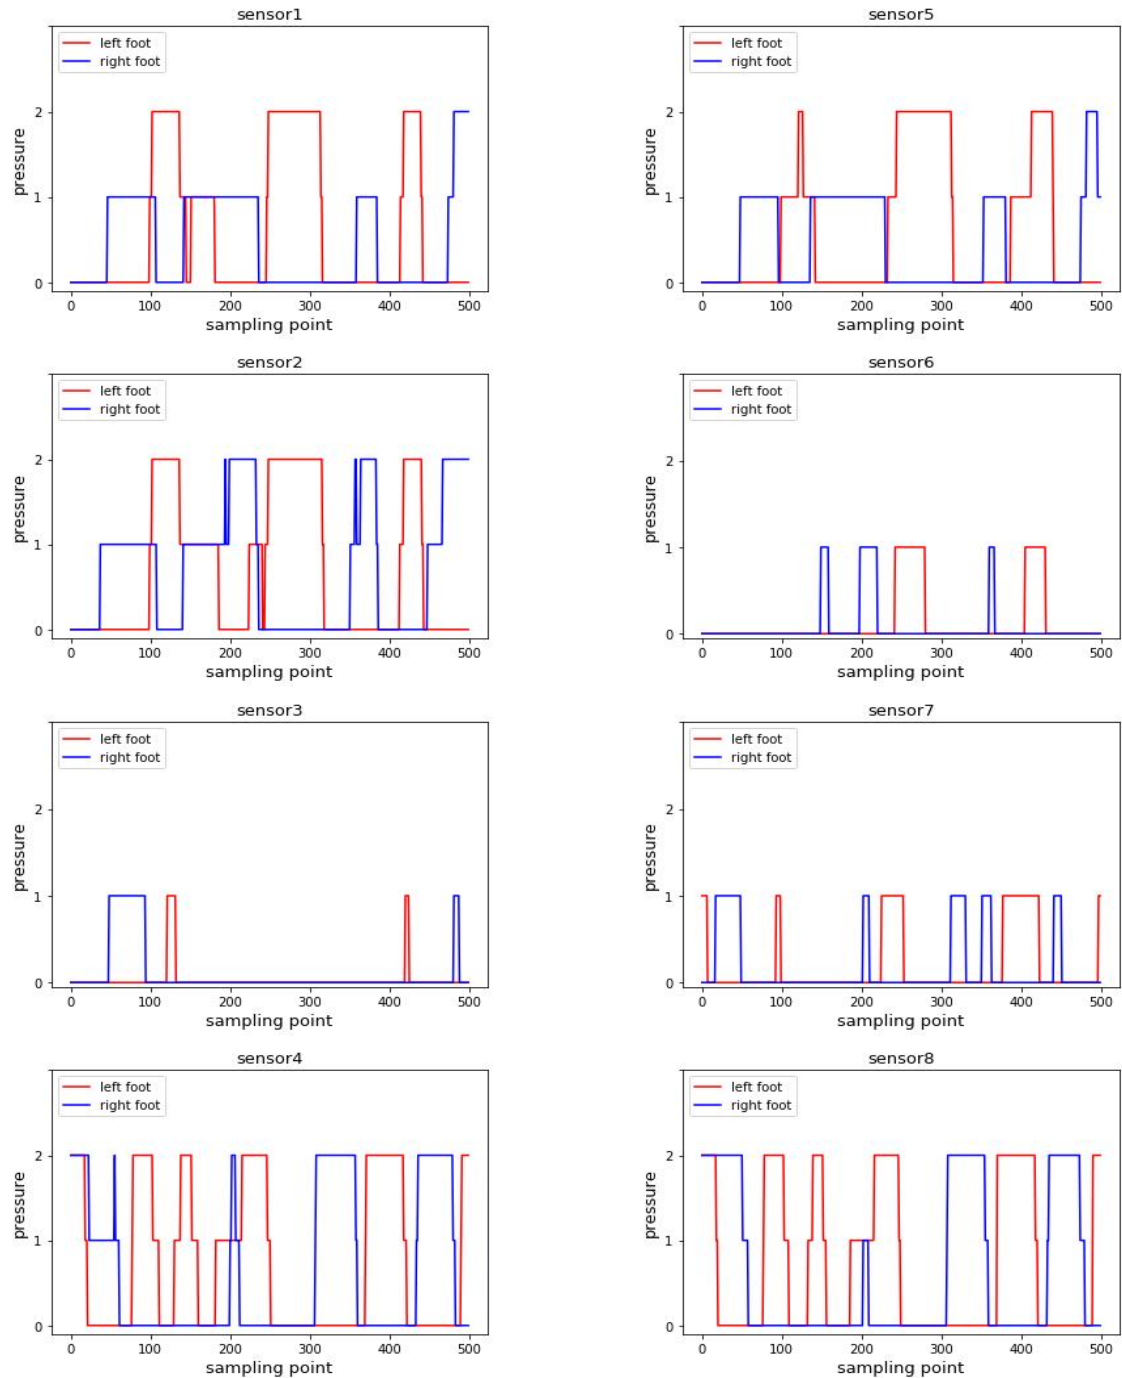


Fig. 9. Measurements of each sensor in both insoles when walking

져 있기 때문에 모든 센서의 값이 0이 되어야 하는 점을 이용하여 swing phase와 stance phase를 검출하는 기준은 다음과 같이 정할 수 있다.

여기서 p 는 어떤 샘플링 포인트에서의 모든 압력 센서값의 합을 의미한다. Fig. 9는 양쪽 깔창의 각 센서의 압력 측정값을 그래프로 표현한 것이다. Fig. 9에서, 보행 시 왼발의 swing phase(발이 지면에서 떨어진 상태, 즉 압력 센서 값이 0인 구간)와 오른발의 swing phase가 서로 교차하는 것을 볼 수 있다. 본 논문에서는 보행 시 왼쪽 발의 swing phase를 검출하여 이를 기준으

로 왼쪽 발의 swing phase의 시작 시점부터 stance phase의 종료 시점까지를 하나의 걸음데이터로 정의하였다.

2. Noise Reduction

센서데이터는 측정 환경, 모듈 내 전위차 및 센서의 열과 같은 요소로 인하여 노이즈가 포함될 수 있다. 이러한 노이즈로 인해 swing phase에서의 8개 중 하나라도 0이 아닌 측정값을 나타낸다면 이는 swing phase 오검출(false positive, FP)을 초래한다. 그리고 한 걸음에 대한 구간은 swing phase에 의해 구성되기 때문에

결과적으로, 분류기 전체의 성능을 악화시킬 수 있다. FP에 해당하는 swing phase들은 정상적인 swing phase에 비해 길이가 짧기 때문에 본 논문에서는 구성된 한 걸음에 대한 구간들 중 0.5초 이하의 길이를 가지는 구간들은 FP swing phase에 의해 생성된 것으로 간주하고 제거하였다. Table 1은 제안한 방법으로 FP에 의한 한걸음 구간들을 제거하고 정상적인 swing phase에 의해 측정된 걸음의 수를 비교한 결과이다.

Table 1. Comparison between the number of steps measured after noise reduction and the actual number of steps

	WK	RA	RD	SA	SD	RUN	FWK
steps measured	176	109	114	55	64	252	186
actual steps	176	114	114	55	65	244	186

3. Gait Data Normalization

보행형태에 영향을 끼치는 변인은 신체적 요인과 지형적 요인 그리고 속도 요인 3가지가 있다. 신체적 요인은 보행자의 나이, 건강상태 등이 있으며, 지형적 요인은 지형의 경사 및 형태가 있고, 속도 요인은 보행자가 걸을 때의 상황 또는 개인 별 차이를 들 수 있다.

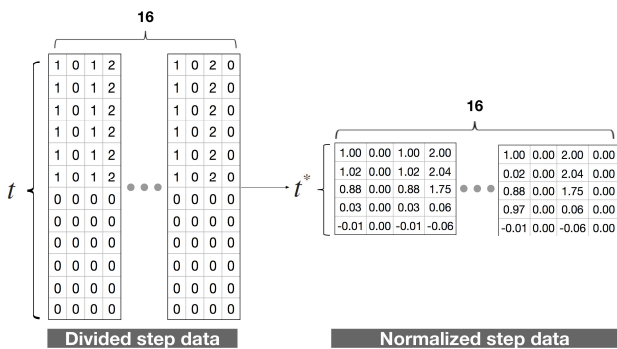


Fig. 10. Example of gait data normalization

위 3가지 변인 중, 보행 속도의 차이는 데이터의 크기에 영향을 주며, 이는 분할된 단위 걸음 데이터 샘플을 이용한 여러 가지 판별 분석을 어렵게 한다. 이에 본 논문에서는 노이즈가 제거된 단위 걸음 데이터 중 가장 짧은 시간을 측정(t^*)한 후, 모든 단위 걸음 데이터를 측정된 단위시간만큼의 길이로 리사이징(resizing)하여 한 걸음에 대한 구간이 동일한 크기를 갖도록 정규화 하였다. Fig. 10은 걸음 데이터를 정규화 하는 예를 보여주고 있다.

$$\text{normalized point} = \frac{\text{non normalized point}}{\text{length of non normalized sign}} \times \frac{\text{length of normalized sign}}{\text{normalized sign}} \quad (13)$$

4. Linear Discriminant Analysis

선형판별분석(LDA)[24, 25, 26]은 멀티 클래스(multi-class) 분류 문제를 위한 특징을 추출하는데 많이 사용되는 방법으로서,

C 개의 클래스로 구성된 N 개의 학습 데이터 x_k 의 클래스 내 산포행렬(S_W)과 클래스 간 산포행렬(S_B)를 식(7)와 (8)와 같이 각각 정의하고 같은 클래스 내 분산과 다른 클래스의 평균들 간 분산의 비율이 최대가 되도록 식(10)과 같이 목적함수를 설정한다.

$$\mu_i = \frac{1}{|C_i|} \sum_{x_k \in C_i} x_k \quad (7)$$

$$S_W = \sum_{i=1}^C \sum_{x_k \in c_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (8)$$

$$S_B = \frac{1}{N} \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (9)$$

$$W_{LDA} = \underset{W}{\operatorname{argmax}} \frac{|W^T S_B W|}{|W^T S_W W|} \quad (10)$$

식(10)의 목적함수를 만족하는 W_{LDA} 는 $S_W^{-1} S_B$ 의 고유값 분석(eigenvalue analysis)을 통해 구할 수 있으며, W_{LDA} 을 이용하여 샘플 x_k 에 대한 특징(y_k)은 $W_{LDA}^T x_k$ 로 구해진다.

한편, 학습 샘플의 개수가 데이터의 차원보다 적을 경우, S_W^{-1} 이 존재하지 않아 식(10)의 해를 구할 수 없는, 이른바 SSS(Small Sample Size) 문제[36]가 발생한다. 이러한 문제점을 해결하기 위해 다양한 알고리즘이 제안되었다[37, 38]. SSS문제를 해결하는 대표적인 알고리즘으로는 PCA를 적용하여 데이터의 차원을 클래스 내 산포행렬(S_w)의 차원보다 낮춘 후 LDA를 적용하는 PCA+LDA[39]와 같은 클래스 내의 데이터를 Null Space로 사영시킨 후 산포행렬이 극대화 되는 부분공간을 탐색하는 Null-LDA[30] 같은 방법이 있다.

전체 산란 행렬(total scatter matrix) S_T 의 고유벡터들로 구성된 사영 행렬을 W_{PCA} 라고 하면, PCA+LDA의 사영행렬은 다음과 같다.

식(10)의 목적함수를 만족하는 W_{LDA} 는 $S_W^{-1} S_B$ 의 고유값 분석(eigenvalue analysis)을 통해 구할 수 있으며, W_{LDA} 을 이용하여 샘플 x_k 에 대한 특징(y_k)은 $W_{LDA}^T x_k$ 로 구해진다.

한편, 학습 샘플의 개수가 데이터의 차원보다 적을 경우, S_W^{-1} 이 존재하지 않아 식(10)의 해를 구할 수 없는, 이른바 SSS(Small Sample Size) 문제[36]가 발생한다. 이러한 문제점을 해결하기 위해 다양한 알고리즘이 제안되었다[37, 38]. SSS문제를 해결하는 대표적인 알고리즘으로는 PCA를 적용하여 데이터의 차원을 클래스 내 산포행렬(S_w)의 차원보다 낮춘 후 LDA를 적용하는 PCA+LDA[39]와 같은 클래스 내의 데이터를 Null Space로 사영시킨 후 산포행렬이 극대화 되는 부분공간을 탐색하는 Null-LDA[30] 같은 방법이 있다.

전체 산란 행렬(total scatter matrix) S_T 의 고유벡터들로 구성된 사영 행렬을 W_{PCA} 라고 하면, PCA+LDA의 사영행렬은 다음과 같다.

Null-LDA는 S_W 의 null 공간을 이용하여 $|W^T S_W W| = 0$ 이

$$W_{LDA} = \operatorname{argmax}_W \frac{|W^T W_{PCA}^T S_B W_{PCA} W|}{|W^T W_{PCA}^T S_W W_{PCA} W|} \quad (11)$$

$$W_{PCA+LDA} = W_{LDA}^T W_{PCA}^T \quad (12)$$

면서 $|W^T S_B W| \neq 0$ 인 공간에서 다음의 목적함수를 만족시키는 사영행렬 W_{NLDA} 를 구한다.

$$W_{NLDA} = \operatorname{argmax}_W |W^T S_{com} W| \quad (13)$$

Null-LDA는 S_W 의 null 공간의 충분히 발생하는 고차원 데이터의 분류에서 좋은 성능을 보이며, 본 논문에서는 보행형태 분류를 위한 선형 판별 분석 방법으로서 Null-LDA를 사용하였다.

IV. Experiments

1. Data Acquisition




Fig. 11. FootLogger sensor

본 논문에서는 보행 데이터 수집을 위해 3L-Labs Co., Ltd.(Seoul Korea)에서 제작한 상용 스마트 깔창인 FootLogger 스마트 깔창을 사용하였다(Fig. 11). FootLogger 깔창은 8개의 압력 센서와 3축가속도 센서, 3축 자이로 센서를 내장하고 있으며 양 쪽 발의 신발에 착용하여 보행 패턴을 측정한다. Fig. 12은 FootLogger 시스템의 구성도이다. 스마트 깔창의 센서 데이터는 블루투스를 통해 스마트폰에 저장된다.

20~30대 성인 13인이 데이터 측정에 참여하였으며, 지형 변화와 속도 변화가 큰 데이터셋을 취득하기 위하여 평지, 계단, 언덕 지형을 걷거나 뛰면서 데이터를 수집하였다. 평지에서 걷기, 경보, 달리기 수집, 언덕에서 오르기, 내리기 수집, 계단에서 오르기, 내리기의 총 7 종류로 구분하였으며, 데이터 수집 시 자연스러운 속도로 보행하도록 하였다. 걷기, 경보, 달리기의 경우 3분 동안 측정하였으며, 언덕 오르내리기는 2분, 계단 오르기와 내리기의 경우는 장소의 제약으로 인해 1분 동안 계단을 걸으며 데이터를 수집하였다. 각각의 보행데이터는 3.1에서 설명한 전처리 과정을 거쳐 816차원 벡터 형태로 저장되었다. Table 2는 측정

된 데이터 샘플에 대한 정보를 보여주고 있다.

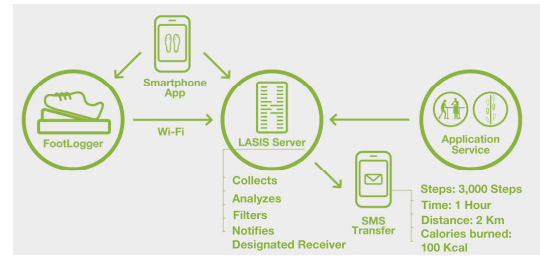


Fig. 12. Schematic diagram of FootLogger

Table 2. Information on gait measurement

terrain	gait type	number of steps	measuring time
flat	walking(WK)	2193	3mins
hill	uphill(RA)	1493	2mins
hill	downhill(RD)	1483	2mins
stairs	climbing stairs (SA)	760	1min
stairs	step down(SD)	838	1min
flat	run(RUN)	3154	3mins
flat	fast run(FWK)	2530	3mins

2. Experimental Results

제안한 보행형태 분류 방법의 성능을 확인하기 위해, FootLogger를 이용하여 취득한 보행 데이터를 III-2에서 설명한대로 전처리를 한 후, 분류 실험을 수행하였다. 선형 판별 분석 기반의 특징추출 방법으로는 Null-LDA를 사용하였다. 전체 데이터 샘플을 임의로 섞은 후, 그 중 절반은 학습데이터로, 나머지 절반을 테스트데이터로 사용하여 분류율을 측정하였으며, 이러한 실험을 20번 반복하여 평균 분류율을 계산하였다. Null-LDA 특징을 추출하기에 앞서, 모든 데이터 샘플들은 학습데이터의 평균과 표준편차로 영 평균(zero-mean), 단위 표준편차(unit standard deviation)을 갖도록 정규화 하였으며, 추출된 특징들을 이용한 분류기로는 NN(nearest neighborhood rule) 분류기를 사용하였다.

전처리 과정을 거친 보행 데이터는 보행형태의 종류에 따라 총 760~3154걸음을 포함하고 있다. 먼저, Null-LDA 특징 공간에서 의미 있는 보행패턴을 추출하기 위해 몇 걸음 정도가 필요한지를 알아보기 위해, 한 걸음을 한 개의 보행 샘플로 구성한 경우에서부터 여섯 걸음을 한 개의 샘플로 구성하는 경우 까지에 대해서 각각 분류 실험을 수행해 보았다. 한 개의 샘플을 한 걸음으로 구성할 경우, 보행 데이터 샘플은 816차원의 벡터로 저장되고, 여섯 걸음으로 구성할 경우는 4896차원의 벡터로 저장된다. Fig. 13는 각각의 경우에 대한 분류율을 보여주고 있다. Fig. 13에서, 한 걸음에서 특징을 추출한 경우와 두 걸음에서 특징을 추출한 경우 분류 성능이 크게 향상된 것을 볼 때 최소한 두 걸음 이상 걸었을 때 유의미한 보행패턴이 발견 되는 것으로 판단된다. 또한 한 개의 샘플이 더 많은 걸음을 포함할수록 조금씩 분류 성능이 높아지는 것은 샘플의 차원이 커질수록 Null-LDA의 특징 공간을 찾는 과정에서 S_W 의 null 공간이 충분히 확보되기 때문인 것으로 보인다. 그러나 샘플의

차원이 증가함에 따라 계산의 양도 증가하기 때문에 차원 증가와 분류 성능 향상의 폭을 고려하여 본 논문에서는 샘플의 크기를 여섯 걸음으로 정하여 실험을 하였다.

한편, [32]에서는 평지, 계단 오르기, 계단 내려가기의 세 종류의 보행형태에 대해서만 분류를 수행한 결과 88%의 분류율을 보였다고 보고하였다. 이에, 세 종류의 보행형태 데이터에 대해 FootLogger의 측정 데이터를 가지고 여섯 걸음을 한 개의 샘플로 구성하여 실험해 본 결과 88%의 분류율이 나왔다. 그러나, [32]와 본 논문의 실험에서 사용된 센서가 다르기 때문에 각각의 분류율을 정량적으로 비교하기에는 어려움이 있다. 그럼에도, [32]에서 사용된 센서가 압력의 세기를 실수(real value) 형태로 측정하는 반면 FootLogger의 경우 0,1,2의 세 종류의 정수 값으로만 데이터를 저장하는 것으로 비추어 볼 때, 제안한 방법이 계산적인 측면에서 [32]에서 사용된 분류방법보다 효율적인 것으로 볼 수 있다. 또한 [32]에서 사용한 센서의 데이터에 제안한 방법을 적용할 경우, 보다 정확한 분류 성능을 얻을 수 있을 것으로 예상된다.

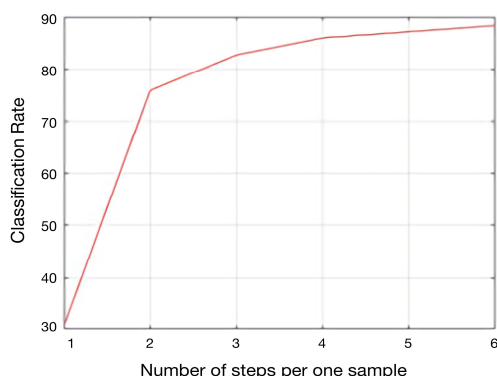


Fig. 13. Classification performance for different numbers of steps included in single sample

V. Conclusions

기존에 제안된 보행 분류기들은 보행 속도와 지형의 변화에 따른 보행패턴의 변이로 인해 안정적인 분류성능을 얻는데 어려움이 있었다. 이에 본 논문에서는 스마트 깔창의 압력 센서만을 이용하여 보행패턴의 변이에도 안정적으로 보행형태를 분류할 수 있는 분류기를 제안하였다.

보행 분류기는 크게 측정 데이터의 노이즈를 제거하고 같은 보행형태 이더라도 보행 속도의 변화나 지형과 같은 보행 환경의 변화 등의 여러 변이를 완화하기 위한 전처리 단계와 전처리된 데이터로부터 보행형태 분류에 적합한 특징을 추출하는 특징추출 단계, 그리고 추출된 특징을 입력으로 받아 최종 보행형태를 결정하는 분류 단계로 나눌 수 있다.

측정 보행 데이터의 전처리 과정에서, 기존의 보행 분류기들이 일정한 크기로 데이터를 분할하는 것과 달리 제안한 방법에서는 swing phase를 기준으로 한 걸음에 해당하는 구간을 검출한 후

모든 걸음들이 동일한 크기를 갖도록 정규화를 함으로써 보행형태 분류 시 보행 속도 변이에 따른 어려움들을 완화시켰다.

보행형태 분류를 위한 특징추출 방법으로는 고차원데이터의 분류에 적합한 Null-LDA 방법을 사용하였다. Null-LDA 방법은 같은 클래스의 데이터들의 분산이 0이 되는 ‘클래스 내 산포 행렬’의 null 공간에서 샘플들의 분산이 최대가 되도록 하는 특징 공간을 찾는다. 제안한 방법에서는 이러한 판별 분석을 보행 데이터에 적용함으로써, 보행 환경에 따라 발생 할 수 있는 보행 데이터의 변이에 대해 강인한 분류 결과를 얻을 수 있었다.

제안한 방법의 효과를 확인하기 위해 상용 스마트 깔창인 FootLogger의 압력 센서로 취득한 보행데이터를 이용하여 7 종류의 보행형태에 대한 보행형태 분류 성능을 평가해 보았다. 하나의 보행 샘플을 몇 걸음으로 정의할 것인지를 결정하기 위해, 한 샘플이 포함하는 걸음 수를 한 걸음에서부터 여섯 걸음까지 변경해 가며 실험해 본 결과, 샘플에 포함된 걸음 수가 최소한 두 걸음 이상일 때 의미 있는 보행형태의 특징이 추출되었으며, 샘플이 많은 걸음을 포함할수록 분류 성능이 향상되는 것을 확인할 수 있었다. 또한 실수(real valued) 압력 측정값을 사용하는 기존 방법과 달리 제안한 방법에서는 0, 1, 2 세 단계의 압력 측정값만을 사용하여 평지, 계단 오르기, 계단 내려가기의 세 종류의 보행형태에 대해 88%의 높은 분류 성능을 나타내었다.

한 편, 그동안 압력 센서 이외에 가속도 센서 또는 자이로 센서를 이용한 보행패턴 분석 방법들도 제안된 바 있다. 본 논문에서의 압력 센서에 대한 판별 분석과 함께 이중 센서들의 측정값에 대한 판별 분석을 함께 사용한다면 보다 향상된 분류 성능을 얻을 수 있을 것으로 기대하며, 이에 대한 연구는 향후 진행할 계획이다.

REFERENCES

- [1] J. Klucken, J. Barth, P. Kugler, J. Schlachetzki, T. Henze, F. Marxreiter, Z. Kohl, R. Steidl, J. Hornegger, B. Eskofier, et al, "Unbiased and Mobile Gait Analysis Detects Motor Impairment in Parkinson's Disease," PLoS ONE, Vol. 8, No. 2, pp. e56956, February 2013.
- [2] D. Gouwanda, Senanayake, S.M.N.A, "Emerging Trends of Body-Mounted Sensors in Sports and Human Gait Analysis," In 4th Kuala Lumpur International Conference on Biomedical Engineering, Osman, N.A.A., Ibrahim, F., Abas, W.A.B.W., Rahman, H.S.A., Ting, H.N., Eds. Springer: New York, NY, USA, Volume 21, pp. 715-718, June 2008.
- [3] Hayashi, Yoshiaki, and Kazuo Kiguchi, "Stairs-ascending /descending assist for a lower-limb power-assist robot considering ZMP," Intelligent Robots and Systems (IROS), IEEE/RSJ International Conference on. IEEE, pp. 1755-1760, September 2011
- [4] Heydarzadeh, Mehrdad, et al, "Gaits analysis using

- pressure image for subject identification," *Biomedical & Health Informatics (BHI)*, 2017 IEEE EMBS International Conference on. IEEE, February 2017.
- [5] Huang, He, Todd A. Kuiken, and Robert D. Lipschutz, "A strategy for identifying locomotion modes using surface electromyography," *IEEE Transactions on Biomedical Engineering*, Vol. 56, No. 1, pp. 65-73, January 2009.
- [6] Se Dong Min, Chun-Ki Kwon, "Step Counts and Posture Monitoring System using Insole Type Textile Capacitive Pressure Sensor for Smart Gait Analysis," *Journal of The Korea Society of Computer and Information*, Vol. 17, No. 8, pp. 107-114, August 2012.
- [7] Seung-Young Kim, Gu-In Kwon, "Gravity Removal and Vector Rotation Algorithm for Step counting using a 3-axis MEMS accelerometer," *Journal of The Korea Society of Computer and Information*, Vol. 19, No. 5, pp. 43-52, May 2014.
- [8] Wu, Wanmin, et al, "Classification accuracies of physical activities using smartphone motion sensors," *Journal of medical Internet research*, Vol. 14, No. 5, October 2012.
- [9] Ngo, Trung Thanh, et al, "Similar gait action recognition using an inertial sensor," *Pattern Recognition*, Vol. 48, No. 4, pp. 1289-1301, April 2015.
- [10] Zhang, Tianxiang, and Gentiane Venture, "Individual recognition from gait using feature value method," *Cybernetics and Information Technologies*, Vol. 12, No. 3, pp. 86-95, March 2012.
- [11] Sprager, Sebastijan, and Matjaz B. Juric, "An efficient HOS-based gait authentication of accelerometer data," *IEEE Transactions on Information Forensics and Security*, Vol. 10, No. 7, pp. 1486-1498, July 2015.
- [12] Sun Hu, and Tao Yuao, "Curve aligning approach for gait authentication based on a wearable accelerometer," *Physiological measurement*, Vol. 33, No. 6, pp. 1111, June 2012.
- [13] Derawi, Mohammad, and Patrick Bours, "Gait and activity recognition using commercial phones," *computers & security*, Vol. 39, pp. 137-144, November 2013.
- [14] Primo, Abena, et al, "Context-aware active authentication using smartphone accelerometer measurements," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pp. 98-105, June 2014.
- [15] Hoang, Thang, et al, "Adaptive Cross-Device Gait Recognition Using a Mobile Accelerometer," *JIPS*, Vol. 9, No. 2, pp. 333, June 2013.
- [16] Hoang, Thang, and Deokjai Choi, "Secure and privacy enhanced gait authentication on smart phone," *The Scientific World Journal*, Vol. 2014, May 2014.
- [17] Muaaz, Muhammad, and René Mayrhofer, "Orientation independent cell phone based gait authentication," *Proceedings of the 12th International Conference on Advances in Mobile Computing and Multimedia*. ACM, pp. 161-164, December 2014.
- [18] Gafurov, Davrondzhon, Kirsi Helkala, and Torkjel Søndrol, "Biometric Gait Authentication Using Accelerometer Sensor," *JCP*, Vol. 1, No. 7, pp. 51-59, November 2006.
- [19] Rong, Liu, et al, "Identification of individual walking patterns using gait acceleration," *Bioinformatics and Biomedical Engineering*, 2007. ICBBE 2007. The 1st International Conference on. IEEE, pp. 543-546, July 2007.
- [20] Rong, Liu, et al, "A wearable acceleration sensor system for gait recognition," *Industrial Electronics and Applications*, 2007. ICIEA 2007. 2nd IEEE Conference on. IEEE, pp. 2654-2659, May 2007.
- [21] Muaaz, Muhammad, and René Mayrhofer, "An analysis of different approaches to gait recognition using cell phone based accelerometers," *Proceedings of International Conference on Advances in Mobile Computing & Multimedia*. ACM, pp. 293, December 2013.
- [22] Ren, Yanzhi, et al, "Smartphone based user verification leveraging gait recognition for mobile healthcare systems," *Sensor, Mesh and Ad Hoc Communications and Networks (SECON)*, 2013 10th Annual IEEE Communications Society Conference on. IEEE, pp. 149-157, June 2013.
- [23] Englehart, Kevin, and Bernard Hudgins, "A robust, real-time control scheme for multifunction myoelectric control," *IEEE transactions on biomedical engineering*, Vol. 50, No. 7, pp. 848-854, July 2003.
- [24] Belhumeur, Peter N, João P. Hespanha, and David J. Kriegman, "Eigenfaces vs. fisherfaces: Recognition using class specific linear projection," *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 19, No. 7, pp. 711-720, July 1997.
- [25] Martínez, Aleix M, and Avinash C. Kak, "Pca versus lda," *IEEE transactions on pattern analysis and machine intelligence*, Vol. 23, No. 2, pp. 228-233, February 2001.
- [26] Yang, Y, S. Choi, and G. Jeong, "LDA-based vapor recognition using image-formed array sensor response for portable electronic nose," *World Congress on Medical Physics and Biomedical Engineering*, Munich, Germany. Springer, Berlin, Heidelberg, pp. 1756-1759, September 2009.
- [27] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp. 1097-1105, December 2012.
- [28] Cortes, Corinna, and Vladimir Vapnik, "Support-vector

- networks," *Machine learning*, Vol. 20, No. 3, pp. 273-297, September 1995.
- [29] Schölkopf, Bernhard, Alexander Smola, and Klaus-Robert Müller, "Kernel principal component analysis," *International Conference on Artificial Neural Networks*. Springer, Berlin, Heidelberg, pp. 583-588, October 1997.
- [30] Cevikalp, Hakan, et al, "Discriminative common vectors for face recognition," *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 27, No. 1, pp. 4-13, January 2005.
- [31] Truong, Phuc Huu, et al, "Stride counting in human walking and walking distance estimation using insole sensors," *Sensors*, Vol. 16, No. 6, pp. 823, June 2016.
- [32] Peng, Zhaoqin, et al, "Human walking pattern recognition based on KPCA and SVM with ground reflex pressure signal," *Mathematical Problems in Engineering*, Vol. 2013, September 2013.
- [33] Golub, Gene H., and Christian Reinsch, "Singular value decomposition and least squares solutions," *Numerische mathematik*, Vol. 14, No. 5, pp. 403-420, April 1970.
- [34] Chen, Meng, Jingyu Yan, and Yangsheng Xu, "Gait pattern classification with integrated shoes," *Intelligent Robots and Systems, 2009. IROS 2009. IEEE/RSJ International Conference on. IEEE*, pp. 833-839, October 2009.
- [35] Chen, Baojun, et al, "A new strategy for parameter optimization to improve phase-dependent locomotion mode recognition," *Neurocomputing*, Vol. 149, pp. 585-593, February 2015.
- [36] Fukunaga, K, "Introduction to statistical pattern recognition," *Access Online via Elsevier*, 2013.
- [37] Huang, Rui, et al, "Solving the small sample size problem of LDA," *IEEE. Pattern Recognition, 2002. Proceedings. 16th International Conference on. Vol. 3. pp. 29-32, August 2002.*
- [38] Lu, Juwei, Kostas N. Plataniotis, and Anastasios N. Venetsanopoulos, "Regularized discriminant analysis for the small sample size problem in face recognition," *Pattern Recognition Letters*, Vol. 24, No. 16, pp. 3079-3087, April 2003.
- [39] Sang-Il. Choi, et al, "Data refinement and channel selection for a portable e-nose system by the use of feature feedback," *Sensors*, Vol. 10, No. 11, pp. 10387-10400, November 2010.
- [40] Shultz, S. Houghlum, P. Perrin, D, "Examination of Musculoskeletal Injuries 2nd ed," *Human Kinetics: Champaign, IL, USA, 2005.*


Authors



Woo-Duk Seo received his B.S. degrees in Mathematics and Economics from Konkuk University in 2015. He is currently pursuing the M.S. degree in the Department of Data Science from Dankook University. His research interests include machine learning and pattern recognition.



Sung-Sin Lee received his B.S. degrees in Software Science from Dankook University in 2016. He is currently pursuing the M.S. degree in the Department of Data Science from Dankook University. His research interests include machine learning and pattern recognition.



Won-Yong Shin received the B.S. degree in electrical engineering from Yonsei University, Seoul, Korea, in 2002. He received the M.S. and the Ph.D. degrees in electrical engineering and computer science from KAIST, Daejeon, Korea, in 2004 and 2008, respectively. From February 2008 to April 2008, he was a visiting scholar in the School of Engineering and Applied Sciences, Harvard University, Cambridge, MA USA. In May 2009, he joined Harvard University as a postdoctoral fellow and was promoted to a research associate in October 2011. Since March 2012, he has been with the Department of Computer Science and Engineering, Dankook University, Yongin, Korea, where he is currently a tenured associate professor. His research interests are in the areas of information theory, communications, signal processing, mobile computing, big data analytics, and online social networks analysis.



Sang-Il Choi received the B.S. degree from the Division of Electronic Engineering, Sogang University, Korea, in 2005 and the Ph.D. degree from the School of Electrical Engineering and Computer Science, Seoul National University, Korea, in 2010. He was a Postdoctoral Researcher in the BK21 Information Technology, Seoul National University, in 2010 and in the Institute for Robotics and Intelligent Systems of Computer Science Department, University of Southern California, Los Angeles, until August of 2011. He is currently an Associate Professor with the Department of Computer Science and Engineering, Dankook University, Korea. His research interests include pattern recognition, feature extraction and selection, machine learning, computer vision, and their applications.