

# 스마트폰의 3축 가속도 센서를 이용한 보행 인식의 기초연구


호종갑, 왕창원, 정화영, 나예지, 김동준\*, 민세동  
 순천향대학교 의료IT공학과  
 \*청주대학교 전자공학과

## Basic Research of Gait Recognition Using 3-axis Accelerometer Sensor of Smart Phone

Jong-Gab Ho, Chang-Won Wang, Hwa-Yung Jung, Ye-Ji Na, Dong-Jun Kim\*, Se-Dong Min  
 Dept. of Medical IT Engineering, SoonChunHyang Univ.  
 \*College of Science & Engineering, Cheong Ju Univ.

**Abstract** - 본 논문에서는 보행 인식의 기초연구로써 성인의 정상적인 보행 및 질환으로 발생 가능한 대표적인 행동 8가지를 스마트폰의 3축 가속도 센서를 이용해 분류하였다. 각 행동은 1분간 30Hz의 샘플링 레이트로 설정하였다. 이동평균필터와 샘플링으로 데이터를 전처리 하였고, 수직, 수평성분 및 평균, 표준편차, 가속도 세기, 상관관계를 특징으로 추출하여 데이터 마이닝 도구인 weka tool을 사용해 7가지의 분류기를 적용하여 각 행동을 분류하였다. 실험 결과 k-NN이 97.1%로 가장 높은 인식률을 나타내었고, 전체 평균 93.74%로 각 행동별 높은 인식률을 보여주었다.

을 각 1분간 실시하였다.(그림 1) 데이터는 스마트폰의 어플리케이션인 SensorLog를 통해 샘플링 레이트를 30Hz로 설정하여 데이터를 획득하였고, (그림 2)는 각 보행별로 3축 가속도 데이터 값을 나타내고 있다.



(그림 1) 피험자 3축 가속도 데이터 측정


### 1. 서 론

우리의 몸은 끊임없이 생체활동을 하며, 이로 인해 발생하는 생체 신호는 생체리듬의 중요한 지표가 된다. 이러한 생체 신호는 심장의 기능을 검사하는 심전도, 근육의 긴장도를 파악하는 근전도, 뇌파의 활동을 검사하는 뇌전도, 임피던스를 이용한 체지방분석을 목적으로 사용되고 있으며 그 외에도 체온, 혈압, 맥박 등의 연구가 활발히 이루어지고 있다. 또한 보행 및 자세 등 신체활동 시 발생하는 생체 신호에 대한 연구도 활발히 진행되고 있다. 그 중 보행은 삶과 가장 밀접된 생체 신호이다. 게다가 건강과도 밀접한 관계를 지니고 있어 보행에 대해 활발하게 연구되고 있다. 대부분의 연구들은 정상인의 보행에 관한 연구를 주로 다뤘다.[1][2][3] 따라서 우리는 질환으로 발생 가능한 보행들을 모니터링하기 위한 기초 연구로써 스마트폰의 3축 가속도 센서를 이용하여 성인의 정상적인 보행 및 질환으로 발생 가능한 대표적인 보행들에 대한 인식을 목적으로 하고 있다. 본 논문의 구성은 다음과 같다. 2장에서는 데이터 획득과 전처리, 특징 추출 및 분류와 실험 결과를 기술하고 있고, 3장에서는 간략한 요약 및 결론을 설명하고 있다.


### 2. 본 론

#### 2.1 데이터 획득


본 연구에서는 스마트폰에 내장된 3축 가속도 센서를 이용하여 가속도 값을 측정하였다. 실험을 위해 스마트폰을 고정시키는 밴드를 제작해 피험자의 허리 측에 착용하여 실험을 진행하였다. 피험자는 총 10명(남성 9명, 여성 1명)의 건강한 성인으로 나이분포는 23세-28세이며 평균 25.3세로 구성하였다. 각 피험자는 정상 보행, 오른쪽 다리 절며 걷기, 왼쪽 다리 절며 걷기, 지팡이 사용해 걷기, 천천히 걷기, 구부리고 걷기, 타인이 휠체어 밀어 주기, 스스로 휠체어 밀기로 총 8가지 보행




(그림 2A) 정상 보행




(그림 2B) 오른쪽다리 절며 걷기




(그림 2C) 왼쪽다리 절며 걷기




(그림 2D) 지팡이 사용해 걷기




(그림 2E) 천천히 걷기



(그림 2F) 구부리고 걷기




(그림 2G) 타인이 휠체어 밀어 주기




(그림 2H) 스스로 휠체어 밀기

## 2.2 데이터 전처리

데이터 전처리는 앞서 얻은 3축 가속도 데이터 값을 샘플링과 이동평균 필터(Moving-Average Filter)를 통해 데이터 잡음을 최소화 해주고 신호를 부드럽게 스무딩(Smoothing) 시켜 주었다. 본 연구에서는 데이터 샘플링을 1000으로 설정하였고, 이동평균 필터의 average point는 최적점인 5로 설정하였다. (그림 3)은 이동평균 필터를 적용한 정상 보행의 데이터와 천천히 걷기의 데이터 값을 나타내고 있다.



(그림 3A) mv-filter 정상 보행



(그림 3B) mv-filter 천천히 걷기

## 2.3 특징 추출 및 분류

데이터 전처리 과정을 거친 3축 가속도 값만으로는 각 보행을 인식하는 데 어려움이 있었다. 특히 왼쪽 절며 걷기와 오른쪽 절며 걷기의 구분, 휠체어를 타인이 밀었을 때와 스스로 밀었을 때의 구분이 쉽지 않았다. 그렇기 때문에 추가적으로 수직, 수평 성분을 구하여 특징으로 삼았다.[4] 수직, 수평 성분은 (식 1)과 같다.

$$\bar{v}_i = \left( \frac{a_i \cdot v_{norm}}{|v_{norm}|^2} \right) v_{norm} \quad (1)$$

$$\bar{h}_i = a_i - \bar{v}_i$$

수직, 수평 성분과 3축 가속도 값의 평균, 표준편차는 선행 연구에서 특징으로 사용했었다. 하지만 왼쪽 절며 걷기와 오른쪽 절며 걷기의 구분이 어려운 문제점이 있었다. 그래서 본 연구에서는 선행 연구[5]의 특징을 기반으로 왼쪽과 오른쪽으로 절며 걷는 자세를 구분하기 위해 3축 가속도 값의 세기와 수직, 수평성분의 상관관계(Correlation)를 추가적인 특징으로 삼았다.[6] 세기

와 관한 것은 (식 3)과 같고 상관관계를 구하는 것은 (식 4)와 같다.

$$M = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (2)$$

$$\rho_{v,h} = \frac{cov(v,h)}{\sigma_v \sigma_h} \quad (3)$$

(식 3)에서  $cov(v,h)$ 는 수직, 수평성분의 공분산(Covariance)을 표현한 것이다. 위의 특징들로 우리는 데이터 마이닝 툴인 Weka tool[7]을 사용해 각 보행을 분류하였다. 분류 방법으로는 Cross Validation 방법을 이용하여 default값인 10-fold를 사용하였고, Bayes Net(BN), Naive Bayes(NB), Logistic regression(Logistic), Multilayer Perceptron(MLP), Support Vector Machine(SVM), k-Nearest Neighbors(k-NN), Decision Tree(DT) 총 8가지의 Classifier로 비교 분석하였다.

## 2.4 실험 결과

Classifier를 적용한 결과는 <표 1>과 같다. 각 분류기에서의 Precision은 BN이 91.4%, NB는 87.9%, Logistic은 94.9%, MLP는 95.8%, SVM은 94%, k-NN은 97.1%, DT는 95.8%의 정확성을 보였다. <표 2>부터 <표 8>까지는 각각 BN, NB, Logistic, MLP, SVM, k-NN, DT의 각 분류기 별 정확성을 자세하게 나타내고 있다. k-NN이 가장 높은 인식률을 보였고, 전체 평균 93.74%로 각 행동별 높은 인식률을 보였다. 선행 연구에서 왼쪽 절며 걷기와 오른쪽 절며 걷기의 평균 인식률은 평균 80.7%였으나 본 연구에서는 94%로 문제점을 보완하였으나 구부려 걷기와 지팡이 걷기의 인식률이 선행 연구 88.9%, 본 연구는 86.7%로 선행 연구보다 약간 낮게 나왔다. 이는 추가 된 특징인 가속도의 세기와 수직, 수평 상관관계가 비슷한 두 행동을 인식에 있어 어려움이 있다고 사료된다.

<표 1> 각 Classifier의 분류 결과

	TP rate	FP rate	Precision	Recall	F-measure
BN	91.2	1.3	91.4	91.2	91.2
NB	87.5	1.8	87.9	87.5	87.5
Logistic	9.5	0.7	94.9	9.5	94.9
MLP	95.8	0.6	95.8	95.8	95.8
SVM	93.9	0.9	94	93.9	93.9
k-NN	97.1	0.4	97.1	97.1	97.1
DT	95.8	0.6	95.8	95.8	95.8

<표 2> Confusion Matrix for Bayes Net

- a)정상 보행, b)오른발 절며 걷기, c)왼발 절며 걷기, d)지팡이 사용해 걷기, e)천천히 걷기, f)구부리고 걷기, g)타인이 휠체어 밀어 주기, h)스스로 휠체어 밀기

		Actual Class							
		a	b	c	d	e	f	g	h
Actual Class	a	995	4	1	0	0	0	0	0
	b	89	854	20	37	0	0	0	0
	c	68	4	918	7	3	0	0	0
	d	0	46	50	792	0	109	0	3
	e	0	5	16	1	978	0	0	0
	f	0	9	11	114	0	866	0	0
	g	0	6	1	18	0	0	944	31
	h	0	6	13	29	0	0	0	952
Precision		0.914	0.864	0.914	0.891	0.794	0.997	0.888	1

〈표 3〉 Confusion Matrix for Naive Bayes

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	955	8	37	0	0	0	0	0	
	b	94	694	78	132	0	2	0	0	
	c	44	46	851	40	19	0	0	0	
	d	0	12	43	708	0	237	0	0	
	e	2	1	14	1	982	0	0	0	
	f	0	0	8	101	0	891	0	0	
	g	1	0	16	0	0	0	975	8	
	h	0	0	32	0	0	0	21	947	
Precision		0.879	0.871	0.912	0.789	0.721	0.981	0.788	0.979	0.992

〈표 4〉 Confusion Matrix for Logistic Regression

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	980	13	7	0	0	0	0	0	
	b	32	930	10	26	1	1	0	0	
	c	11	7	968	7	4	3	0	0	
	d	0	29	15	837	1	118	0	0	
	e	0	1	4	0	995	0	0	0	
	f	0	0	1	97	0	902	0	0	
	g	0	0	0	0	0	0	991	9	
	h	0	0	0	0	0	0	7	993	
Precision		0.949	0.958	0.949	0.963	0.866	0.994	0.881	0.993	0.991

〈표 5〉 Confusion Matrix for Multilayer Perceptron

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	997	2	1	0	0	0	0	0	
	b	8	968	10	14	0	0	0	0	
	c	2	12	972	3	9	2	0	0	
	d	0	35	10	851	1	103	0	0	
	e	0	1	7	0	992	0	0	0	
	f	0	1	1	89	0	909	0	0	
	g	0	0	0	0	0	0	983	17	
	h	0	0	0	0	0	0	9	991	
Precision		0.958	0.99	0.95	0.971	0.889	0.99	0.896	0.991	0.983

〈표 6〉 Confusion Matrix for Support Vector Machine

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	998	2	0	0	0	0	0	0	
	b	63	916	7	14	0	0	0	0	
	c	17	3	955	3	22	0	0	0	
	d	0	31	14	789	7	159	0	0	
	e	2	2	0	0	996	0	0	0	
	f	0	0	0	78	0	922	0	0	
	g	0	0	0	0	0	0	987	13	
	h	0	0	0	0	0	0	48	952	
Precision		0.94	0.924	0.96	0.978	0.893	0.972	0.853	0.954	0.987

〈표 7〉 Confusion Matrix for k-Nearest Neighbors

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	1000	0	0	0	0	0	0	0	
	b	5	972	4	19	0	0	0	0	
	c	1	2	983	1	13	0	0	0	
	d	0	8	5	924	0	63	0	0	
	e	0	0	5	0	995	0	0	0	
	f	0	0	0	74	0	926	0	0	
	g	0	0	0	0	0	0	985	15	
	h	0	0	0	0	0	0	16	984	
Precision		0.971	0.994	0.99	0.986	0.908	0.987	0.936	0.984	0.985

〈표 8〉 Confusion Matrix for Decision Tree

		Actual Class								
		a	b	c	d	e	f	g	h	
Actual Class	a	979	16	4	0	0	1	0	0	
	b	20	931	12	33	0	4	0	0	
	c	6	12	959	10	11	2	0	0	
	d	0	21	11	910	0	58	0	0	
	e	0	0	6	0	993	0	1	0	
	f	0	3	4	67	0	926	0	0	
	g	0	0	0	0	0	0	985	15	
	h	0	0	0	0	0	0	22	978	
Precision		0.958	0.974	0.947	0.963	0.892	0.989	0.934	0.977	0.985

### 3. 결 론

본 연구는 질환으로 발생 가능한 보행들을 모니터링 하기 위한 기초 연구로서 성인의 정상적인 보행 및 질환으로 발생 가능한 대표적인 보행 8가지를 인식하는 것을 목적으로 하였다. 실험은 건강한 성인을 대상으로 3축 가속도 센서가 내장된 핸드폰을 밴드 형태로 제작하여 허리 측에 착용해 3축 가속도 데이터를 측정하였다. 데이터 전처리는 각 행동 별 데이터들을 1000으로 샘플링 하고 이동 평균필터를 적용함으로써 잡음을 제거하고 데이터를 부드럽게 완화시켜 주었다. 전처리한 데이터는 3축 가속도의 평균, 표준편차와 수직, 수평 성분 그리고 3축 가속도 세기 값과 수직, 수평축의 상관관계를 구해 각 보행을 인식하기 위한 특징으로 삼았다. 보행 인식을 위한 도구로써 Weka tool을 사용하였고, Cross-Validation의 10-fold로 Bayes Net(BN), Naive Bayes(NB), Logistic regression(Logistic), Multilayer Perceptron(MLP), Support Vector Machine(SVM), k-Nearest Neighbors(k-NN), Decision Tree(DT) 총 7가지의 분류기를 적용시켰다. 그 결과 k-NN이 97.1%로 가장 높은 인식률을 보였고, 전체 평균 93.74%로 높은 인식률을 보였다. 이를 통해 각 보행별 인식이 가능한 것을 확인 할 수 있었다. 향후 연구에서는 본 실험을 토대로 어플리케이션을 제작하고 허리측만이 아닌 어느 곳에 위치하든 측정이 가능하도록 할 예정이다. 이후에는 정밀하게 행동 인지를 하기 위해서 3축 가속도 센서와 더불어 압력 센서나 전도성 섬유 센서를 추가 할 계획이다.

### 4. 감사의 글

이 논문은 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단 바이오·의료기술개발사업의 지원을 받아 수행된 연구임(NRF-2015M3A9D7067388).

### [참 고 문 헌]

- [1] Jani Mantyjarvi, Mikko Lindholm, "Identifying users of portable devices from gait pattern with accelerometers", ICASSP '05, IEEE international Conference, Vol.2, ii/973-ii/976, 2005
- [2] Do-Un Jeong, Se-Jin Kim, Wan-Young Chung, "Classification of Posture and Movement Using a 3-axis Accelerometer", International Conference on Convergence Information Technology 2007, pp837-844, 2007
- [3] M.J. Mathie, A. C. F. Coster, B.G. Celler, and N. H. Lovell, "Classification of basic daily movements using a triaxial accelerometer", Med. Biol. Eng. Comput., vol.42, pp.670-687, 2004
- [4] David Mizell, "Using gravity to estimate accelerometer orientation", Proceedings of the Seventh IEEE international Symposium on Wearable Computers (ISWC 03), Vol.1530 no.0811/03, pp252-253, 2003.
- [5] 왕창원, 호종갑, 나예지, 정화영, "3축 가속도 센서를 이용한 행동 인식 비교", 2015 한국정보처리학술대회(추계) 논문집, 2015년 10월 30일-31일, 제주 한라대학교
- [6] Yun-young Nam, Jung-Wook Park, "Physical activity recognition using a single triaxial accelerometer and a barometric sensor for baby and child care in a home environment", Journal of Ambient Intelligence and Smart Environments, vol.5 no.4, pp.381-402, 2013
- [7] Weka 3 Data Mining with Open Source Machine Learning Software in Java, <http://www.cs.waikato.ac.nz/ml/weka/index.html>