

사용자 운동 상태 추정을 위한 가속도센서 신호처리 기술

백중훈, 이기혁*
경북대학교 정보통신학과
*한국정보통신대학교 공학부

Accelerometer Signal Processing for User Activity Detection

Jonghun Back, Geehyuk Lee*

Dept. of Information and Communication, Kyungpook National University

Dept. of Engineering, Information and Communication University*

E-mail: jhback@inc.knu.ac.kr, geehyuk@icu.ac.kr

Abstract

Estimation of human motion states is important enabling technologies for realizing a pervasive computing environment. In this paper, an improved method for estimating human motion state from accelerometer data is introduced. Our method for estimating human motion state utilizes various statistics of accelerometer data, such as mean, standard variation, skewness, kurtosis, eccentricity, as features for classification, and therefore is expected to be more robust than other existing methods that rely on only a few simple statistics. A series of experiments for testing the effectiveness of the proposed method has been performed, and its result is presented.

I. 서론

Pervasive computing 은 누구나 쉽게 접속 가능한 무수한 컴퓨터 디바이스들이 Ubiquitous Network 에 연결되어 있는 컴퓨터 환경으로 정의할 수 있다. 예컨대 컴퓨터나 센서가 수많은 디바이스, 장치, 사무실, 공장 심지어 입을 컴퓨터인 Wearable Computer 등 모든 곳에 존재하는 상황을 말한다. Wearable Computer 는 사용자가 어떤 환경에 있건 쉽고 간편하게 컴퓨터 리소스에 접근하게 한다. 언제 어디에서나 사용자의 개인 공간 안에 포함되어 작동되고 상호작용을 이룸으로써 우수한 이동성과 이용상의 편리성을 제공하게 된다.[1][2]

본 논문은 옥내에서 Wearable Computer 에 필요한

사용자의 운동 상태 추정을 제안한다. 이 기술은 사용자의 운동 상태를 감지하여 옥내의 특정 위치에서 사용자의 행동에 따라 적절한 서비스를 제공하고, 다른 센서 기술과의 결합으로 사용자의 위치, 운동 상태, 건강 상태 등 모든 인체 활동을 포괄적으로 예측 가능하다. 이러한 사용자의 현재 활동 상태를 결정하기 위해서 가속도센서를 사용하였다.

II. 데이터 처리

각 운동 상태들에 대한 데이터는 사용자의 허리에 2 축 가속도센서(ADXL202EB)를 부착하여 사용자의 운동 상태에 따라 가속도센서의 X 축(수직방향) 과 Y 축(수평방향)에서 얻어진다. 그리고 각각의 상태들에 대해 2 초간 측정했다. 사용자 운동 상태를 추정하기 위해서 실험을 통해 수집된 데이터들로부터 특징 추출을 하여, 클러스터링 알고리즘인 신경망을 사용하여 구분하였다.[3]




그림 1. 사용자 운동 상태 추정을 위한 block diagram

2.1 특징 추출

정적인 상태들 사이에서의 가속도센서의 출력은 그

림 2와 같이 가속도센서의 방향이 서로 다르기 때문에 쉽게 구분이 가능하였다. [4] 그러나 동적인 상태들 사




그림 2. Standing, Sitting, Lying 상태의 가속도센서 방향

이에서는 가속도센서의 방향이 서로 같이 때문에 가속도센서의 방향만으로 구분하기가 어렵다. 그림 3.의 아래 타원은 동적인 상태들에 대한 데이터 분포의 형성을 나타내는데, 이와 같이 동적인 상태들의 구분은 데이터 분포의 모양으로 구분하였다.




그림 3. Walking, Running, Upstairs, Downstairs 상태에서

가속도센서의 움직임

사용자 운동 상태 추정을 위해서 가속도센서의 수평, 수직 출력 데이터의 분포에 대한 특성들을 이용하여, 중심 위치와 각 출력 데이터 주위에 흩어져 있는 정도 그리고 데이터 분포의 모양과 기울어진 방향과 정도 등을 특징으로 사용하였다. 그리고 각 운동 상태들에 대한 데이터 분포를 알아보기 위해서 가속도센서 출력 데이터의 분포를 나타내는 히스토그램(그림 4.)을 구하고, 분포의 특징값들을 이용하였다.




그림 4. 정적인 상태(위)와 동적인 상태(아래)의 X, Y 히스토그램
그림 4.의 정적인 상태와 같이 가속도 센서의 출력 데이터 분포가 각기 다른 특징값에 집중적으로 분포되어

분산이 거의 “0”임을 알 수 있다. 따라서 사용자 운동 상태의 정적인 상태는 매우 쉽게 구분되어진다. 그림 4.의 동적인 상태에서는 출력 데이터 값이 넓게 분포되어 있으므로, 분산으로부터 정적인 상태와 분명히 구분되어 지며, 동적인 상태들 사이의 데이터 분포의 대칭성, 분포의 기울어진 정도와 방향 그리고 데이터 분포의 뾰족한 정도 등이 사용자의 활동 상태에 따라 다르게 관찰되었다. 이러한 분포 특징을 이용하여 동적인 상태를 구분하였다.

2.1.1 평균(Mean)

평균은 데이터 분포의 특성을 한 개의 수치로 나타내는 대표값이다. 그림 4.에서 본 히스토그램에서 각 구간의 중심값에 그 구간에 해당하는 데이터의 개수를 곱하여 나타낼 수 있다. 즉 히스토그램을 이용한 평균은 다음과 같이 정의 된다.

$$\mu = \frac{1}{N} \sum_{i=1}^k c_i \cdot n_i$$




그림 5. X, Y에 대한 평균의 분포

그림 5.에서 평균은 정적인 상태들 사이에서 구분 가능하였고, Standing 과 동적인 상태들이 클러스터를 구상하기 때문에 구분이 불가능하였다. 이는 가속도센서의 방향이 같이 때문이다.

2.1.2 표준편차(Standard Deviation)

표준편차는 사용자의 운동 상태에 따라 가속도센서의 출력 데이터들의 값이 흩어져있는 정도를 나타내는데 이용된다. 즉 X·Y 데이터들의 평균을 중심으로 얼마나 데이터가 집중되어 있는지 또는 퍼져 있는지 그 흩어져있는 정도를 나타낸다.

$$\sigma_H = \sqrt{\frac{1}{N} \sum_{i=0}^k (c_i - \mu)^2 \cdot n_i}$$

그림 6.에서 정적인 상태에서의 데이터들은 각 운동 상태의 특정한 값에 모두 분포되어 분산이 거의 “ 0”의 값을 가지므로 구분하기가 불가능하였고,

분포가 넓게 형성되는 동적인 상태와는 분산에 의해서 구분이 가능하였다.




그림 6. X, Y에 대한 표준편차의 분포

동적인 상태들 사이에서는 데이터 분포가 넓게 분포되어 있는 Running, Downstairs 상태들은 Walking, Upstairs 상태와 구분이 가능하였다.

2.1.3 이심률(Eccentricity)

사용자 운동 상태에 대한 출력 데이터를 그림 7과 같이 출력 데이터를 근사화하는 타원을 구할 수 있다. 이 때 “타원이 얼마나 찌그러져 있는가?”와 “타원의 기울기의 방향이 다른가?”에 따라서 특징을 선택할 수 있다.




그림 7. 동적인 상태들에 대한 데이터 분포 모양

이러한 이심률은 위식으로 표현되어지는데, 이는 Covariance Matrix의 고유치를 구하는 것이다.

$$y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = Ax = \begin{bmatrix} \sum_{i=1}^N (x_i - C_x)^2 & \sum_{i=1}^N (x_i - C_x)(y_i - C_y) \\ \sum_{i=1}^N (x_i - C_x)(y_i - C_y) & \sum_{i=1}^N (y_i - C_y)^2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$




그림 8 고유치 e1, e2의 분포

그림 8에서 정적인 운동 상태에서는 거의 모든 X•Y 값이 원래의 값에서 변화가 거의 없으므로 이심률은 거의 “0”의 값을 가진다. 그러나 동적인

운동 상태에서는 원래의 X•Y에서 변동이 많으므로 고유치는 정적인 운동 상태에 비해 높은 값을 가지게 된다. 그림 7에서 이심률이 큰 값을 가지는 Walking과 Upstairs의 타원이 가장 심하게 찌그러져 있다는 것을 볼 수 있다. 이심률은 Walking, Upstairs 상태와 Running 상태 구분이 가능하였다.

2.1.4 왜도(Skewness)

왜도는 X•Y 출력 데이터 분포의 기울어진 방향과 정도를 나타낸다. 즉, 평균에 대한 분포의 비대칭 정도를 나타내는 것이다. 왜도는 아래식으로 표현되어진다.

$$Skewness = \frac{3rd - moments}{\sigma^3}$$




그림 9. X, Y에 대한 왜도의 분포

그림 9에서 정적인 상태에서는 모두 “0”의 값을 가지는데 이는 분산이 거의 “0”의 값을 가지기 때문이다. 동적인 상태들 사이에서의 X 축은 그림 9.에서와 같이 Walking, Running과 Upstairs, Downstairs를 구분할 수 있고, Y 축은 Walking과 Running 그리고 Upstairs를 구분할 수 있었다.

2.1.5 첨도(Kurtosis)

첨도는 왜도와 같이 X•Y 출력 데이터 분포 모양을 나타낸다. 왜도와는 달리 데이터 분포의 모양이 얼마나 뾰족한지, 평편한지를 나타내는 지표이다. 첨도는 아래식으로 표현되어진다.

$$Kurtosis = \frac{4th - moments}{\sigma^4}$$




그림 10. X, Y에 대한 첨도의 분포

그림 4에서 Running 운동 상태에서 가장 편평한 분포를 가지므로 그림 10.의 X에 대한 첨도의 분포에

서 다른 운동 상태에 비해 가장 작은 값의 분포를 가진다. 따라서 척도는 Running, Walking 과 Upstairs, Downstairs 를 구분할 수 있었다.

III. 신경망 분석

각 운동 상태를 추정하기 위한 클러스터링 알고리즘은 신경망의 Backpropagation 알고리즘을 이용하여 구분하였다. 각각의 입력층에는 위에서 살펴본 특징들이 입력 패턴이 되고, 이 입력 신호는 각 뉴런에서 변화되어 은닉층에 전달하게된다. 실험 과정에서 은닉층의 수를 변화시키면서 에러율의 변화를 학습 곡선을 통하여 확인하였다. 그리고 훈련 데이터를 사용하여 결정된 가중치를 실험 데이터에 적용함으로써 학습의 정도와 에러율을 측정하였다. 실험 데이터는 훈련 데이터 수집과 같은 방법으로 2 초간 수집했다.




그림 11.1 은닉층 뉴런 수가 14 개일 때의 에러 곡선과 테스트 결과




그림 11.2 은닉층 뉴런 수가 13 개일 때의 에러 곡선과 테스트 결과




그림 11.3 은닉층 뉴런 수가 12 개일 때의 에러 곡선과 테스트 결과

그림 11.의 테스트 결과에서 x 축은 실험 데이터를 나타내며 0~30 까지가 Standing, 31~60 은 Sitting, 61~90 은 Lying back, 91~120 은 Lying on, 121~150 은 Walking, 151~180 은 Running, 181~210 은 Upstairs, 211~240 은 Downstairs 를 나타내고, y 축은 각 상태들에 대한 목표값을 나타낸다.

그림 11.은 학습 반복횟수에 따라서 학습을 한 결과이며, 은닉층의 수가 늘어날수록 연산 시간이 매우 증가되기 때문에 은닉층의 뉴런의 수를 줄여가면서 실험한 결과를 나타내었다. 실험 결과 은닉층의 뉴런 수가 12 개일 때 실험 데이터에 대해서 100% 구분함을 알 수 있다.

위 시뮬레이션 결과에서 은닉층의 뉴런의 수가 많아질수록 에러가 더 낮아져, 신경망이 훈련 데이터에 지나치게 맞추어져서 실제 실험 데이터에 적용했을 때의 성능은 오히려 더 낮아졌다. 따라서 은닉층의 뉴런의 개수에 따라 Over-Fitting 의 정도가 달라짐을 알 수 있었다.

IV. 결론

본 논문에서는 2 축 가속도센서를 사용자 신체에 부착시켜 사용자의 Standing, Sitting, Lying, Walking, Running, Upstairs 그리고 Downstairs 하는 신체의 다양한 운동 상태를 실험 데이터에 대해서 100% 구분하였다. 앞으로는 실험 대상자를 통해 많은 훈련 데이터를 이용하여 다양하게 학습함으로써 많은 사람들에게 적용할 수 있도록 해야 한다. 그리고 가속도센서가 항상 사용자의 몸에서 흔들리지 않고, 가속도센서 방향이 일정하다는 가정에서 실험을 하였으나, 앞으로는 사용자 운동 상태 추정을 위해서 가속도센서가 PDA, 휴대폰 그리고 Wearable Computer 에 장착되어 보다 유용하게 사용될 수 있도록 특징 추출을 위한 연구와 클러스터링 알고리즘에 대한 연구가 폭 넓게 진행되어야 한다.

참고문헌

- [1] 전자신문, “외국의 유비쿼르스 IT 혁명 전략”, <http://www.etimesi.com>, Dec, 06, 2002
- [2] 코리아인터넷닷컴, “입는 컴퓨터(Wearable Computer)”, <http://korea.internet.com>, Aug, 06,2001
- [3] C.Randell; H.Muller, “Context Awareness by Analysing Accelerometer Data” , The Fourth International Symposium on Wearable Computers, pp.175~176, 2000.
- [4] J. Farrington; A J. Moore; M Tilbury, J. Church; P. D. Biemond, “Wearable Sensor Badge & Sensor Jacket for Context Awareness” , Proceedings of the 3rd International Symposium on Wearable Computers, IEEE, pp.107~113, 1999