
가속도 센서 기반 사용자 비정상 행동 검출 탑-다운 접근 방법 제안

Top-down Approach for User Abnormal Activity Detection Based on the Accelerometer

이민석, Min Seok Lee*, 임종관, Jong Gwan Lim**, 권동수, Dong Soo Kwon***

요약 기존 사용자의 행동 패턴을 인식하는 연구들이 몇 개의 특정 행동을 설정, 사용자 독립적인 인식 결과를 낼 수 있는 특징 추출 방법들을 제안해왔다. 그러나 이러한 연구는 실험실 차원의 결과에 그치고 사용자 독립적인 일반성 획득이나 특정 행동만을 인식 대상으로 삼음으로써 구현상에서 많은 어려움을 초래한다. 이러한 문제점을 개선하고자 본 논문에서는 사용자의 일정 기간 동안의 행동 패턴에 대해 반복성과 지속성을 기준으로 새로 입력되는 행동 패턴의 정상/비정상 여부를 검출한다. 기존 연구에서 사용한 교차학습 방법이 아닌 비교학습 방법을 적용, 일정 기간 동안 수집된 데이터를 클러스터링하여 반복성을 평가하는 기준으로 삼는다. 실험을 통해 반복적으로 발생하는 데이터를 근거로 하여 처음 나타난 행동을 비정상 행동으로 검출할 수 있음을 입증했다.

Abstract The method to get the feature have been proposed to recognize the user activity by setting specific action for making the user independent result in previous research. However, it was only applied in specific environment and it was difficult to implement because it regarded only some specific feature as the recognized object. To improve this problem we detected the normality/abnormality of the activity based on the repetition and the continuity of the past activity pattern. We applied the unsupervised learning method, not supervised, and clustered the data which was collected within a certain period of time and we regarded it as the basis of the evaluation of the repetition. We demonstrated to be able to detect the abnormal activity based on whether the data was generated repeatedly.

핵심어: *Activity Detection, Signal Processing, HCI, Accelerometer*

본 연구는 지식경제부 및 정보통신연구진흥원의 IT 핵심기술개발사업의 일환으로 수행하였음. [2008-F039-01, 인간-로봇 상호작용 매개기술 개발]

*주저자 : KAIST 로봇공학학제전공 석사과정 e-mail: leems@robot.kaist.ac.kr

**공동저자 : KAIST 기계공학과 박사과정 e-mail: limjg@robot.kaist.ac.kr

***교신저자 : KAIST 기계공학과 교수 e-mail: kwonds@kaist.ac.kr

1. 서론

우리나라 노인인구는 현재 전체인구의 7%를 넘고 있으며, 2030년에는 65세 이상 노인이 국민의 23%인 1천만 명을 넘을 것으로 추정된다[1]. 본격적인 고령사회로 접어드는 전 단계인 고령화 사회에서는 노인의 신체적 취약성으로 인한 안전문제가 사회문제로 대두하게 된다.

노인은 일반적으로 인지, 판단능력, 상황대처능력이 떨어져 잦은 안전사고가 발생한다. 또한 노인의 신체적 취약성은 낙상, 추락, 미끄러짐 등의 작은 안전사고가 자칫 인명피해로까지 연결될 수 있다는 점이 지적되고 있다.

본 논문에서는 가속도계를 이용하여 사용자의 행동패턴을 인식함으로써 정상 행동과 이상 행동을 구분하고 주어진 문제의 해결책을 제시하고자 한다. 본 논문에서 언급하는 정상 행동은 사용자에게 사고가 발생하지 않는 정상시의 행동패턴을 의미하며 이상 행동은 사고 혹은 여러 다른 문제에 의하여 위험에 처한 상황의 행동 패턴을 보이는 경우를 의미한다. 정상적인 행동패턴과 이상 행동패턴의 구분은 결과적으로 노인들의 안전사고의 빠른 감지를 통하여 더 큰 피해로까지 연결되는 것을 막을 수 있다. 적은 사람이 다수의 노인 관리에도 용이해 앞으로의 노인 인구의 비율 증가 문제에 대한 대처방안이 될 수 있다. 또한 노인 뿐 아니라 혹은 장애인 혹은 환자들의 급성 질환 - 경련 등을 감지함으로써 더 큰 사고를 미연에 방지할 수 있을 것으로 기대하고 있다.

행동패턴을 인식하기 위하여 여러 입력 장치가 제안되었다. 카메라를 기반으로 하는 행동패턴 인지 방법이 제안되었지만[2] 이는 공간 제약의 한계를 극복하지 못하였다. 상대적 위치를 측정하는 가속도계를 이용한 행동패턴의 인식은 공간상의 제약을 받지 않는다는 점에서 연구가 이루어지고 있다[3, 4]. 본 논문에서 역시 가속도 센서를 이용한 방법을 제안함으로써 공간 제약을 받지 않는 시스템을 설계하고자 한다.

2. 관련 연구

가속도 센서를 이용한 행동패턴의 인식의 기존 연구를 살펴보면 Baek은 주어진 행동패턴을 바탕으로 2축 가속도 센서를 이용하는 방법을 제시하였다[3]. 사람의 기본적인 행동패턴을 논하고 각 패턴에 따른 구간별 통계적 모델을 이용하여 특징벡터를 구하였다. Ravi는 3축 가속도 센서를 이용하여 행동패턴을 구간으로 하는 특징벡터를 찾기보다 일반적인 특성을 나타낼 수 있는 특징벡터를 찾는 연구를 진행하였다[4]. 나이가 Bao는 5개의 2축 가속도 센서를 몸의 움직임이 많은 곳 - 팔꿈치 등에 부착하고 행동패턴을 인식하고자 하였다[5].

지금까지 가속도 센서를 이용하여 행동패턴을 인식하는 연구는 인식하고자 하는 행동패턴을 기준으로 하는 교사학습(supervised learning)을 통한 행동패턴을 인식하였다. 이 방법들은 정상행동과 이상행동 구분에 적용하는 데 다음과 같은 문제점을 노출한다.

첫째로 서로 다른 사용자의 같은 행동 패턴의 인식 결과는 같은 사용자를 통한 행동 패턴의 인식 결과보다 낮은 것을 볼 수 있다. 모든 사람들은 같은 행동에 대하여 다른 행동을 보이며 - 예를 들어 걸음걸이의 행동패턴 - 이는 서로 다른 인식결과로 나타난다. 한 사람에게는 극히 정상적인 행동들을 가리키는 가속도 신호가 다른 사람에게는 비정상적인 행동의 가속도 신호로 나타날 수 있다. 개인에 따른 다른 결과를 바탕으로 한 학습 메커니즘을 사용하여 정확도를 높일 필요가 있다.

둘째로는 행동패턴의 다양성에 대한 문제이다. 사람이 행할 수 있는 행동패턴은 매우 다양하여 기존의 교사학습만으로는 모든 행동패턴을 분류하는 것이 불가능하다.

언급한 문제점으로 인하여 사용자의 정상 행동 패턴과 이상 행동패턴을 구분하는 데 어려움이 있다. 본 논문에서는 정상 행동과 이상 행동패턴을 구분하는 방법론에 대한 제시를 하고자 한다.

3. 제안하는 방법

정상 행동과 이상 행동을 구분하기 위하여 정확한 기준이 필요하다.

본 논문에서의 이상 행동의 기준은 낙상, 추락 등의 사고 위험을 수반할 가능성이 있는 행동을 의미한다. 대체로 이상 행동 패턴은 정상적인 과거의 행동 패턴에 의존적이다. 따라서 과거의 학습된 결과를 토대로 이상 행동 패턴을 구분하는 방법을 제안한다.

이상 행동은 크게 두 가지로 나눌 수 있다. 순간의 행동패턴이 과거에 존재하지 않는 행동 패턴을 이상 행동으로 간주함으로써 행동 패턴 자체에 관련된 이상 행동을 추정할 수도 있으며 또 다른 하나로 만약 주어진 행동 패턴이 과거에 존재하는 행동패턴이라고 하더라도 기존에 없던 행동의 급작스러운 변화 혹은 평소에 오래 지속하지 않던 행동의 오랜 지속 등의 시간과 관련된 이상 행동을 의미할 수 있다.

과거의 학습된 행동 패턴 분류 결과를 바탕으로 실시간으로 입력된 행동 패턴을 기존에 주어진 클래스를 찾고 해당하는 클래스가 존재하면 정상 패턴으로 인지하고 해당하는 클래스가 존재하지 않으면 이상 행동으로 분류할 수 있다. 이를 위하여 비교사학습 방법의 인식을 제안하며 이로써 개선된 k-Nearest Neighbors(이하 개선된 kNN)를 제안하

고자 한다. 개선된 kNN은 기존의 클래스의 개수가 처음부터 주어지고 이를 기준으로 클러스터링의 종료시점이 정해지는 일반적인 kNN과 달리 특징벡터간의 임계 거리를 클래스의 구분 기준으로 삼는다. 이는 행동패턴의 개수에 독립적이어야 하는 이상 행동의 분류 목적에 잘 부합한다고 할 수 있겠다.

4. 신호 추출 및 실험

본 연구에 대한 검증 을 위하여 하드웨어 설계 및 실험 방법을 제안한다. 그리고 결과를 분석하여 성능을 평가한다.

4.1 하드웨어 설계

가속도 센서는 사람의 무게중심과 사용자 편의를 고려해야만 한다. 사람의 무게중심인 요천(腰薦)으로부터 가장 가까우면서 사용자의 몸에 착용하고 자유롭게 움직일 수 있는 등의 벨트 착용부에 부착되었다[6]. 가속도 센서로는 3축 가속도 센서를 사용하여(AM-3AXIS VER.2, N.T.C) 이 중 좌우, 앞뒤, 위아래 방향의 3축 데이터를 사용하였다. 3축을 모두 이용하여 추락 등의 무중력 상태에 가까운 행동패턴의 인식이 가능하다. 가속도 신호는 마이크로프로세서(ATmega8L, ATmel)로 아날로그 신호로 입력되며 이는 8-bit resolution을 갖는 디지털 신호로 변환된다. 변환된 가속도 신호를 저장 을 위하여 4Mb Flash Memory(AT45DB041B, ATmel)를 사용한다.

4.2 특징 벡터 추출

특징벡터로서 움직임의 DC 성분을 알아내기 위하여 각 3축에 대한 구간별 평균을 사용하였다. 또한 움직임의 크기 변화를 측정하기 위하여 구간별 분산을 사용하였다[4].

마지막으로 주파수 성분에 대한 변화를 관측하기 위하여 다음과 같은 특징 벡터를 제안하였다.

먼저 주파수 분석을 위하여 주어진 구간 내의 FFT의 결과를 구한다. 기본주파수 및 보조주파수를 구하기 위하여 주파수 함수의 극점(Local Maximum)을 구한다. 극점을 크기에 따라 정렬하고 i 번째로 큰 극점을 갖는 주파수의 크기를 s_i 라 하면 제안하는 특징벡터의 Frequency Maximum Ratio는

$$FMR = 2 \left(\frac{\sum_{k=1}^2 s_k}{\sum_{k=1}^5 s_k} - 0.5 \right) \quad (1)$$

로 제안할 수 있다.

4.3 신호 처리

가속도 신호는 초당 512 sample이 추출된다. 이 신호는 가속도 센서 내부에서 발생하는 과도한 impulse 잡음을 제거하기 위하여 과거 네 개의 신호를 포함하여 다섯 개의 신호 정보로 중간값 필터를 통해 여과된다. 8개의 데이터가 추출되면 이는 Anti-aliasing 필터 및 저주파 대역 필터로서 Mean 필터를 거치고 이 정보는 메모리에 저장된다. 메모리에 저장되는 주파수는 초당 62.5 sample이다.




그림 1 행동패턴 인식 인터페이스 하드웨어




그림 2 신호 처리 구조

메모리에 저장된 데이터는 실험이 끝난 후 분석을 위하여 RS-232를 통하여 컴퓨터에 저장된다. 특징벡터를 추출하기 위하여 각 125 sample 구간마다 윈도우를 씌우고 윈도우 안에서 각 세 축에 대한 평균, 분산, FMR을 구한다. 이는 매 30 sample (0.48sec)마다 계산되어 특징벡터로 사용된다.

4.4 실험

우리가 원하는 신호를 얻기 위하여 다음과 같이 한 명의 피실험자에 대하여 다음 실험을 진행하였다.

피실험자는 가속도계를 착용 후 현재 위치에서 약 10m 떨어져 있는 계단으로 이동한다. 계단을 이용하여 3층으로

올라간 후 약 50m 떨어진 곳에 위치한 바닥에 위치한 주어진 책을 집어 올린다. 책을 쓰인 표지를 읽은 후 위치에 내려놓고 길을 따라 다시 내려온다. 한 층의 계단의 개수는 총 24개이며 한 층을 오르기 위하여 12개의 계단을 오른 후 뒤를 돌아 다시 남은 12개의 계단을 올라가야 하는 구조이다. 실험 시간은 2분 54초이다.

실험의 성능 비교를 하기 위하여 기준 실험과 함께 동일한 업무에 대하여 3회의 실험을 수행하였다. 또한 이 실험과의 대조군을 구하기 위하여 기준 실험과 다른 업무에 대한 실험 결과를 측정하였다. 다른 업무는 평지를 달린 후 자전거타기와 약 500g의 물건을 2m 높이의 선반에 올려놓는 작업이다. 평지를 약 56초 달린 후 약 2분 거리를 자전거를 타고 선반에 도착하여 물건을 선반에 올린 후 다시 같은 거리의 선반에 도착하여 같은 업무를 3회 수행한 후 돌아온다. 총 9분 18초의 업무 수행 시간이 소요된다. 앞으로 이 업무를 비교 업무라고 칭하겠다.

4.5 인식기 설계

분류기로 실시간 개선된 kNN을 사용하여 각 행동패턴에 따른 클러스터링을 수행하였다. 시작 데이터를 첫 그룹으로 생성하고 실시간으로 입력되는 데이터는 각 그룹과의 거리를 계산한 뒤 가장 거리가 가까운 그룹과 임계값을 비교한다. 거리가 임계값보다 작다면 그룹 내의 원소로 등록하고 임계값보다 크다면 새로운 클래스를 생성한다(그림 3).




그림 3 실시간 kNN의 순서도

4.6 실험 결과

학습에 사용된 피실험자의 데이터를 입력으로 하여 분류기의 성능을 실험하였다. 먼저 분류기의 성능을 평가하기 위하여 위의 실험 데이터 중 첫 번째 실험 데이터의 계층 구조 clustering을 수행하였다. 첫 번째 실험 데이터를 기준으로 다른 실험 데이터의 클러스터링을 수행한다면 같은 업무를 수행할 때의 행동패턴은 크게 다르지 않을 것이다. 따라서 새로 나타나는 클래스의 발생 빈도에 따라 특징 벡터 및 행동 패턴 인식의 성능을 평가할 수 있을 것이다.

특징벡터로는 지면과 수직방향 및 사용자의 좌우 방향에 대한 FMR, 3축에 대한 평균, 3축에 대한 분산으로 총 8차원의 특징벡터를 사용하였다.

기준 실험 데이터의 계층 구조 클러스터링의 결과 패턴은 총 12개의 행동패턴으로 분류되었다. 첫 번째 실험의 데이터 개수는 353개이다. 같은 업무를 추가적으로 3회 수행하였을 때와 비교 업무를 수행하였을 때 패턴 분류 결과를 표 1에 나타내었다.

표 1. 업무에 따른 패턴의 동일성 비교

업무 종류	동일업무	비교 업무
업무 데이터 개수	1142	1162
새로 등록된 패턴	4	22
추가 패턴에 포함되는 데이터	20	671
추가 패턴에 포함되는 데이터의 백분율(%)	1.75	57.75

업무간의 데이터 집합을 형성하는 그룹에 대하여 같은 그룹으로 추정되는 행동 패턴 그룹간 거리를 측정하여 그룹간 동일한 정도를 측정하고자 한다. 평가 방법은 다음과 같다.

먼저 네 개의 업무 수행 데이터 집합 중 각 수행된 데이터의 집합을 선택하고 다른 업무의 그룹 중 가장 거리가 가까운 그룹을 찾는다. 즉, i 번째 수행된 업무 데이터의 k 번째 그룹 중 j 번째 데이터 집합에의 그룹과 가장 가까운 그룹간 거리를 $d_{i,j,k}$ 라 하면

$$(2)$$

여기서 n_i 는 i 번째 업무 집합 중 j 번째 그룹의 그룹 좌표를 의미하며 n_i 는 i 번째 업무 집합의 그룹 개수이다.

모든 $d_{i,j,k}$ 에 대하여 각 업무 집합간의 오차 $e_{i,j}$ 는

$$e_{i,j} = \sqrt{\frac{\sum_{k=1}^{n_i} m_{i,k} d_{i,j,k}}{\sum_{l=1}^{n_i} m_{i,l}}} \quad (3)$$

로 나타낼 수 있다. 여기서 $m_{i,j}$ 는 i 번째 업무 데이터 집합의 j 번째 그룹의 데이터 개수이다.

각 업무 집합의 오차를 표 2에 나타내었다.

표 2. 각 업무에 대한 각 실험 데이터에 대하여 서로 같은 그룹의 벡터로 추정되는 값의 오차

Disturbance Term	동일업무	비교업무
업무 집합 오차	0.09787	0.26347

5. 결론 및 향후계획

5.1 결론

등에 부착된 가속도센서로부터 사용자의 행동패턴을 추정하는 시스템을 개발하였다. 기존의 행동패턴 인지방법과 달리 과거의 행동패턴 결과로 학습을 하고 매 입력 신호의 클래스를 분류하고 새로운 클래스라 인식되면 새로 생성이 가능한 시스템이다. 이는 사용자 독립적인 시스템을 가능케 하고 수많은 행동패턴을 분류할 수 있는 시스템이라고 할 수 있다.

실험을 통하여 서로 비슷한 행동패턴을 보이는 업무에 비하여 서로 다른 행동패턴을 보이는 업무는 새로 나타나는 클래스의 개수 증가와 추가된 패턴으로 포함되는 데이터의 증가를 관측할 수 있었다. 또한 비교업무에 대한 업무집합간의 오차 역시 동일업무보다 크다는 것을 확인할 수 있었다. 다양한 행동패턴은 자율학습(unsupervised learning)을 이용하였을 때 더욱 효과적이며 노인 혹은 장애우의 이상 행동패턴을 감지하고자 할 때 적합한 시스템이라고 할 수 있다.

5.2 향후 계획

본 논문에서 이 시스템의 검증은 한 사람에게만 이루어졌다. 사용자의 변화가 어떠한 결과를 야기하는 지 실험을 통한 검증이 필요하다.

하나의 업무가 아닌 다양한 업무에 대한 접근 방법이 필요하겠다. 업무의 절반의 변화, 전체적인 변화에 따른 클래스의 변화를 찾아볼 수 있다.

기존 논문에서 제시되었던 교사학습 방식의 행동패턴 인식과 결합하는 것도 생각해볼 수 있다. 기본적으로 동일하게 갖는 행동패턴에 대하여 초기패턴을 갖고 시간의 흐름에 따른 클래스의 갱신을 생각해 볼 수 있다.

시스템을 적용하기 위하여 무선 모듈이 필요하다. 메모리

의 저장만으로는 사용자 정보를 전달할 수 없다. 현재 MITes 등의 가속도센서와 무선 통신 모듈이 결합된 제품이 등장하고 있다[8]. 집적화를 통한 소형화는 개발자들에게 더 많은 기회를 제공하고 있다.

마지막으로 시간에 의존적인 행동 패턴의 분류기를 설계하고 시간에 의존하는 이상 행동 패턴 감지를 하는 특징 벡터 추출 및 구현을 최종 목표로 한다.

참고문헌

- [1] 대한민국 통계청, 2002
- [2] Anant Madabhushi, J. K. Aggarwal, "A Bayesian Approach to Human Activity Recognition", Visual Surveillance, 1999. pp.25-32.
- [3] Jonghun Baek, Geehyuk Lee, Wonbae Park, Byoung-Ju Yun, "Accelerometer Signal Processing for User Activity Detection", KES 2004, LNAI 3215, pp. 610-617 2004.
- [4] Nishkam Ravi, Nikhil Dandekar, Preetham Mysore, Michael L. Littman, "Activity Recognition from Accelerometer Data", Proceeding of the National Conference on Artificial Intelligence, v.20 no.3, 2005, pp.1541-1546.
- [5] Ling Bao, Stephen S. Intille, "Activity Recognition from User-Annotated Acceleration Data", PERVASIVE 2004, LNCS 3001, pp. 1-17, 2004.
- [6] Masaki Sekine, Toshiyo Tamura, Toshiro Fujimoto, Yasuhiro Kukui, "Classification of walking pattern using acceleration waveform in elderly people", EMBS, 22nd, July 23-28, 2000.
- [7] S. Theodoridis and K. Koutroumbas, "Pattern Recognition, 3/e, " Academic Press, San Diego, 2003.
- [8] Emmanuel Munguia Tapia, Natalia Marmasse, Stephen S. Intille, Kent Larson, "MITes: Wireless Portable Sensors for Studying Behavior"