

3축 가속도 센서를 이용한 행동 인식 비교

왕창원, 호종갑, 나예지, 정화영, 남윤영*, 민세동
 순천향대학교 의료IT공학과
 *순천향대학교 컴퓨터공학과

changwon@sch.ac.kr, hodori1988@naver.com, nayeji1649@naver.com,
 hwayung89@gmail.com, ynam@sch.ac.kr*, sedongmin@sch.ac.kr

A comparison of activity recognition using a triaxial accelerometer sensor

ChangWon Wang, JongGab Ho, YeJi Na, HwaYung Jung, YunYoung Nam*,
 Se Dong Min

Dept. of Medical IT Eng., Soonchunhyang University

*Dept. of Computer Science and Eng., Soonchunhyang University

요 약

본 연구에서는 노인들이 일상에서 많이 행동하는 7가지 유형의 행동의 특징을 추출하고, 총 7가지 분류 알고리즘에 적용하여 가장 인식률이 높은 알고리즘을 도출하고자 하였다. 행동패턴은 정상보행, 절름발이, 지팡이, 느린 보행, 허리가 굽은 상태에서 보행, 스스로 휠체어 끌 때 그리고 누군가가 휠체어를 끌어줄 때 총 7가지로 구성하였다. 행동패턴의 특징은 3축 가속도 센서의 값, 평균, 표준편차, 수직 및 수평축의 데이터를 사용하였다. 분류 알고리즘은 Naive Bayes, Bayes Net, k-NN, SVM, Decision Tree, Multilayer perception, Logistic regression을 사용하였다. 연구결과 k-NN 알고리즘의 인식률이 98.7%로 다른 분류알고리즘에 비해 인식률이 높게 나타났다.

1. 서론

최근 전 세계적으로 인간의 수명이 증가하고 있고, 이에 따른 노인들에 대한 의료비 문제가 사회적으로 중요 이슈로 대두되고 있다[1-2]. 그 중 낙상 사고는 연령에 관계없이 발생이 가능하며, 특히 65세 이상의 노인에서 많이 발생한다[3]. 미국의 경우 65세 이상 노인의 약 30%, 80세 이상 노인의 약 40%가 1년에 1회 이상 낙상을 경험하는 것으로 나타났고, 낙상이나 낙상 관련 상해로 입원한 노인의 50%가 1년 이내에 사망하는 것으로 보고되었다[4].

이에 낙상검출과 관련되어 3축 가속도 센서, 자이로 센서, 카메라 등 IT기기를 활용하여 낙상을 검출하는 연구가 다양하게 진행되고 있다. 하지만 낙상을 예방 및 예측하는 연구는 많이 미흡한 실정이다.

따라서 본 연구에서는 65세 이상 노인들의 낙상을 예측 및 예방하는 시스템을 개발하기 위한 선행연구로 진행되었다. 노인들이 일상생활에서 많이 행동하는 7가지 유형의 행동을 선정하고, 각 행동에 대한 특징을 추출하였다. 그리고 7가지의 분류 알고리즘을 적용하여 인식률이 가장 높은 알고리즘을 도출하고자 하였다.

본 논문의 구성은 2장 본문에서 데이터 획득, 전처리, 분류기법에 대해 설명하고, 3장에서는 실험 결과를 기술하며, 4장에서 결론을 맺는다.

본 연구에서는 안드로이드 기반 스마트폰의 3축 가속도 센서를 이용하여 데이터를 획득 하였다(그림 1). 데이터는 1분 동안 30Hz로 샘플링 하였고, 스마트폰에 저장하도록 구성하였다. 보행 패턴은 정상보행, 절름발이, 지팡이, 느린 보행, 허리가 굽은 상태에서의 보행, 스스로 휠체어 끌기, 누군가가 뒤에서 휠체어 끌기, 총 7가지로 구성하였고, 3축 가속도 데이터를 획득하였다(그림 2). 보행패턴 선정 기준은 노인들의 일상적으로 자주 행동하는 것으로 선정하였다.

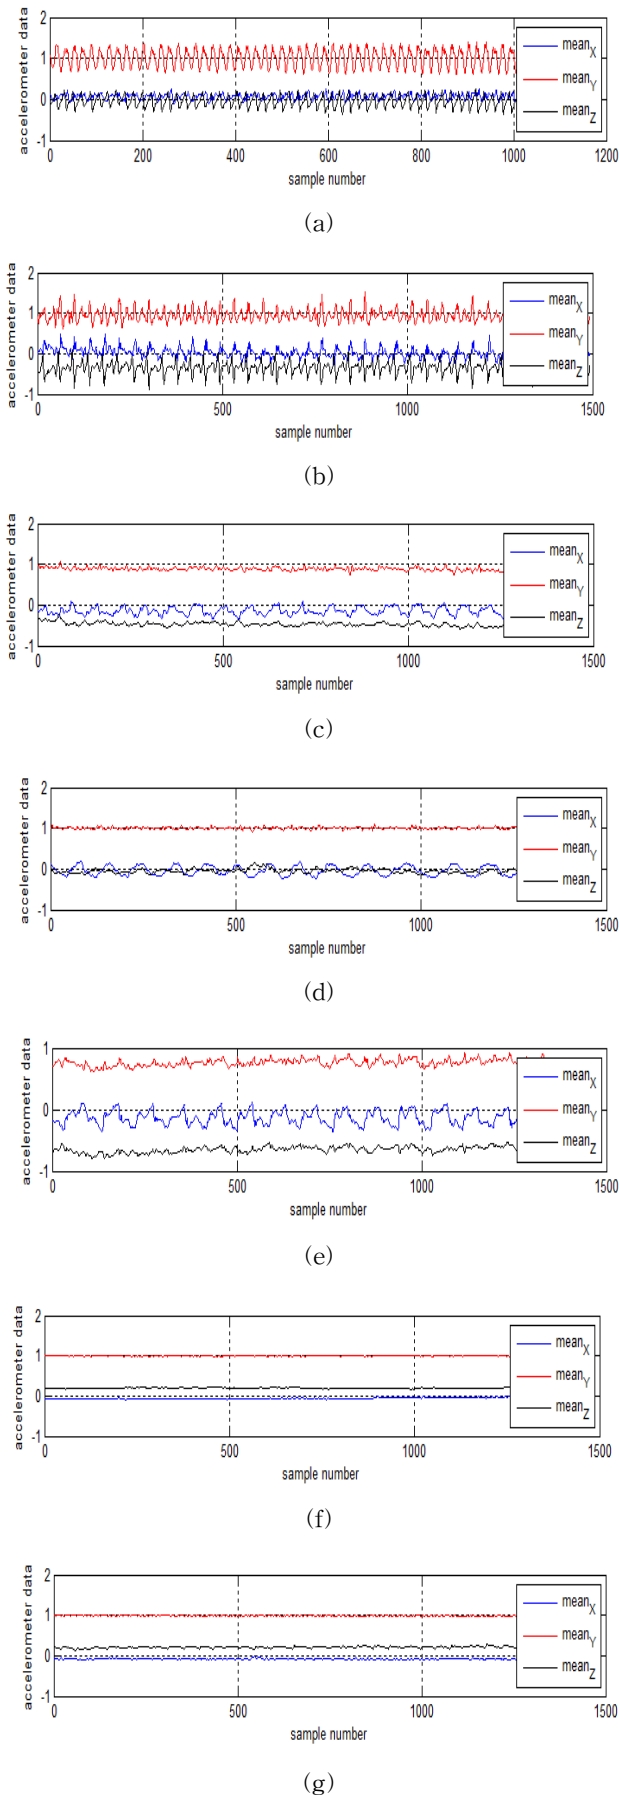
피험자는 신체적으로 건강한 성인 10명(남성 8명, 여성 2명)을 선정하였다. 피험자들의 평균 나이는 25.3세, 연령분포는 23-28세로 구성하였다.



(그림 1) 안드로이드 기반 스마트폰의 3축 가속도 센서

2. 본론

2.1 데이터 획득

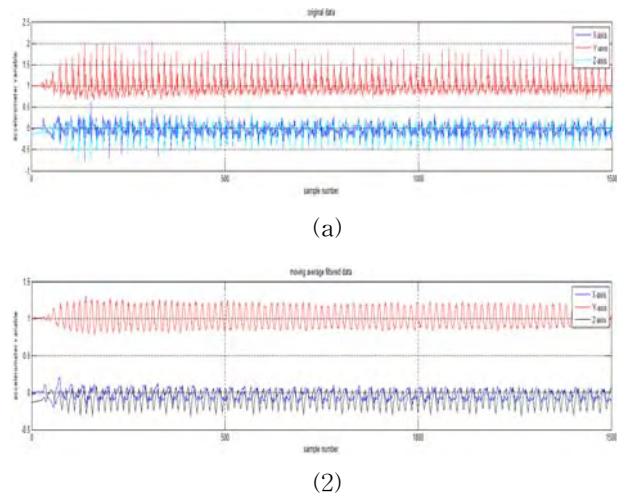


(그림 2) 7가지 행동패턴의 3축 가속도 데이터 a)


정상보행, b) 절름발이 보행, c) 지팡이, d) 느린 보행, e) 허리가 굽은 상태에서의 보행, f) 스스로 휠체어 끌기, g) 누군가가 뒤에서 휠체어 끌기

2.2 데이터 전처리

데이터 전처리과정은 Moving average filtering을 통해 jittering 잡음을 제거하고 신호를 smoothing하게 만들었다(그림 3). 선행연구[5]에서 average point가 5일 때, 가장 효과적으로 jittering 잡음을 제거하고 신호가 smooth하게 나타났다. 따라서 본 연구에서는 average point를 5로 설정하였다. 또한 행동 인식률을 올리기 위해 수평 및 수직 축의 데이터를 추출하였다(그림 4).



(그림 3) 3축 가속도 센서의 정상보행 데이터 a) 원신호 b) moving average 필터링 된 신호



(그림 4) 수직 및 수평 데이터 특징

2.3 데이터 인식 및 분류

본 연구에서는 3축 가속도 센서값, 센서값의 평균, 표준편차, 수직 및 수평 데이터를 데이터 인식에 특징점으로 사용하였다. 데이터 분류는 Weka툴의 10-fold cross validation방법을 이용하여 Naive Bayes(NB), Decision Tree(DT), Support Vector Machine(SVM), Bayes Net(BN), Multilayer perception(MLP), Logistic Regression(Logistic), k-Nearest Neighbors(k-NN) 알고리

즘을 사용하였다.

3. 결과

아래의 <표 1>은 7가지 유형의 행동에 대한 인식 결과이다. 7가지의 분류 알고리즘 중에 k-NN이 98.7%로 정확도가 가장 높게 나타났고, Naive Bayes가 93%로 가장 낮게 나타났다.

<표 1> 각 유형에 대한 인식 결과

| Classifier | TP rate | FP rate | Precision | Recall | F-measure |
|------------|---------|---------|-----------|--------|-----------|
| NB | 92.7% | 1.2% | 93% | 92.7% | 92.7% |
| BN | 93.4% | 1.1% | 93.4% | 93.4% | 93.4% |
| SVM | 94% | 1% | 94.5% | 94% | 94% |
| k-NN | 98.7% | 0.2% | 98.7% | 98.7% | 98.7% |
| DT | 96.3% | 0.6% | 96.3% | 96.3% | 96.3% |
| MLP | 95.8% | 0.7% | 95.8% | 95.8% | 95.8% |
| Logistic | 96.3% | 0.6% | 96.3% | 96.3% | 96.3% |

총 7가지 행동 유형에 대한 모든 행동 패턴의 인식률 평균은 0.95로 나타났다. 각 알고리즘의 평균 인식률은 정상보행에서는 0.981, 질름발이 보행에서는 0.959, 지팡이에서는 0.97, 느린 보행에서는 0.989, 허리가 굽은 상태에서의 보행에서는 0.978, 스스로 휠체어 끌기는 0.907, 누군가가 뒤에서 휠체어 끌기는 0.893으로 나타났다.

휠체어 같은 경우, 0.907, 0.893으로 나타나면서 인식률이 가장 낮게 나타났다. 각 알고리즘 별 인식률을 보면, NB에서는 0.951, 0.776, BN에서는 0.915, 0.851, SVM에서는 0.764, 0.943, k-NN에서는 0.954, 0.926, DT에서는 0.926, 0.922, MLP에서는 0.9, 0.891, Logistic에서는 0.923, 0.918로 나타났다.

<표 2> Confusion Matrix for Naive Bayes

- a) 정상보행, b) 질름발이, c) 지팡이, d) 느린 보행, e) 허리가 굽은 상태에서의 보행, f) 스스로 휠체어 끌기, g) 누군가가 뒤에서 휠체어 끌기

| | | Predicted Class | | | | | | |
|--------------|-------|-----------------|-------|-------|-------|-------|-------|-------|
| | | a | b | c | d | e | f | g |
| Actual Class | a | 1085 | 53 | 0 | 12 | 0 | 3 | 7 |
| | b | 36 | 1375 | 41 | 7 | 60 | 1 | 0 |
| | c | 0 | 61 | 1434 | 0 | 40 | 0 | 0 |
| | d | 0 | 4 | 0 | 1476 | 0 | 0 | 17 |
| | e | 0 | 0 | 14 | 0 | 1382 | 0 | 0 |
| | f | 0 | 0 | 0 | 0 | 0 | 1417 | 310 |
| | g | 0 | 0 | 0 | 17 | 0 | 69 | 1159 |
| Precision | 0.927 | 0.968 | 0.921 | 0.963 | 0.987 | 0.933 | 0.951 | 0.776 |

<표 3> Confusion Matrix for BayesNet

| | | Predicted Class | | | | | | |
|--------------|-------|-----------------|-------|-------|-------|-------|-------|-------|
| | | a | b | c | d | e | f | g |
| Actual Class | a | 1088 | 59 | 0 | 5 | 0 | 0 | 0 |
| | b | 33 | 1405 | 56 | 16 | 65 | 0 | 0 |
| | c | 0 | 27 | 1412 | 7 | 17 | 0 | 0 |
| | d | 0 | 2 | 0 | 1460 | 0 | 0 | 7 |
| | e | 0 | 0 | 22 | 0 | 1398 | 0 | 1 |
| | f | 0 | 0 | 0 | 0 | 0 | 1363 | 127 |
| | g | 0 | 0 | 0 | 7 | 0 | 174 | 1270 |
| Precision | 0.934 | 0.971 | 0.941 | 0.948 | 0.977 | 0.943 | 0.915 | 0.851 |

<표 4> Confusion Matrix for SVM

| | | Predicted Class | | | | | | |
|--------------|------|-----------------|-------|-------|-------|-------|-------|-------|
| | | a | b | c | d | e | f | g |
| Actual Class | a | 1106 | 57 | 0 | 6 | 0 | 3 | 5 |
| | b | 15 | 1425 | 23 | 0 | 0 | 0 | 0 |
| | c | 0 | 11 | 1449 | 0 | 11 | 0 | 0 |
| | d | 0 | 0 | 0 | 1468 | 0 | 0 | 0 |
| | e | 0 | 0 | 18 | 0 | 1471 | 0 | 0 |
| | f | 0 | 0 | 0 | 6 | 0 | 1138 | 80 |
| | g | 0 | 0 | 0 | 15 | 0 | 349 | 1408 |
| Precision | 0.94 | 0.987 | 0.954 | 0.972 | 0.982 | 0.993 | 0.764 | 0.943 |

<표 5> Confusion Matrix for K-NN

| | | Predicted Class | | | | | | |
|--------------|-------|-----------------|-------|-------|------|-------|-------|-------|
| | | a | b | c | d | e | f | g |
| Actual Class | a | 1121 | 5 | 0 | 0 | 0 | 0 | 0 |
| | b | 0 | 1476 | 5 | 0 | 0 | 0 | 0 |
| | c | 0 | 12 | 1479 | 0 | 2 | 0 | 0 |
| | d | 0 | 0 | 0 | 1495 | 0 | 0 | 0 |
| | e | 0 | 0 | 6 | 0 | 1480 | 0 | 0 |
| | f | 0 | 0 | 0 | 0 | 0 | 1453 | 68 |
| | g | 0 | 0 | 0 | 0 | 0 | 37 | 1425 |
| Precision | 0.987 | 1 | 0.989 | 0.993 | 1 | 0.999 | 0.975 | 0.954 |

<표 6> Confusion Matrix for Decision Tree

| | | Predicted Class | | | | | | |
|--------------|-------|-----------------|-------|-------|-------|-------|-------|-------|
| | | a | b | c | d | e | f | g |
| Actual Class | a | 1100 | 25 | 0 | 1 | 0 | 0 | 0 |
| | b | 21 | 1438 | 24 | 5 | 1 | 2 | 0 |
| | c | 0 | 26 | 1449 | 0 | 16 | 0 | 0 |
| | d | 0 | 3 | 0 | 1485 | 0 | 0 | 3 |
| | e | 0 | 1 | 16 | 0 | 1465 | 0 | 1 |
| | f | 0 | 2 | 0 | 0 | 0 | 1379 | 109 |
| | g | 0 | 0 | 0 | 3 | 0 | 113 | 1377 |
| Precision | 0.963 | 0.981 | 0.963 | 0.972 | 0.993 | 0.989 | 0.926 | 0.922 |

<표 7> Confusion Matrix for Multilayer Perception

| | | Predicted Class | | | | | | | |
|--------------|---|-----------------|-------|-------|-------|------|-------|------|-------|
| | | a | b | c | d | e | f | g | |
| Actual Class | a | 1108 | 12 | 0 | 7 | 0 | 1 | 1 | |
| | b | 13 | 1468 | 11 | 2 | 0 | 0 | 0 | |
| | c | 0 | 11 | 1436 | 0 | 1 | 0 | 0 | |
| | d | 0 | 2 | 0 | 1480 | 0 | 2 | 11 | |
| | e | 0 | 0 | 30 | 0 | 1479 | 0 | 0 | |
| | f | 0 | 0 | 0 | 4 | 0 | 1341 | 150 | |
| | g | 0 | 0 | 0 | 4 | 0 | 146 | 1331 | |
| Precision | | 0.958 | 0.988 | 0.983 | 0.964 | 0.99 | 0.998 | 0.9 | 0.891 |

<표 8> Confusion Matrix for Logistic Regression

| | | Predicted Class | | | | | | | |
|--------------|---|-----------------|-------|-------|------|-------|-------|-------|-------|
| | | a | b | c | d | e | f | g | |
| Actual Class | a | 1093 | 35 | 0 | 3 | 0 | 0 | 0 | |
| | b | 26 | 1438 | 16 | 3 | 1 | 0 | 0 | |
| | c | 0 | 16 | 1460 | 0 | 10 | 0 | 0 | |
| | d | 1 | 3 | 0 | 1486 | 0 | 1 | 0 | |
| | e | 0 | 1 | 17 | 0 | 1472 | 0 | 0 | |
| | f | 0 | 0 | 0 | 1 | 0 | 1375 | 123 | |
| | g | 1 | 0 | 0 | 4 | 0 | 114 | 1370 | |
| Precision | | 0.963 | 0.975 | 0.963 | 0.98 | 0.994 | 0.993 | 0.923 | 0.918 |

4. 결론

본 연구에서는 65세 이상 노인들이 일상에서 많이 행동하는 7가지 유형의 행동의 특징을 추출하고, 7가지 분류 알고리즘에 적용하였다. 이를 통해 가장 인식률이 높은 알고리즘을 도출하여 향후 65세 이상 노인의 행동인식에 사용할 분류 알고리즘을 도출하고자 하였다. 행동 패턴의 특징은 3축 가속도 센서의 x축, y축, z축의 값, 평균, 표준편차, 그리고 수직 및 수평축의 데이터를 사용하였다. 행동 패턴은 총 7가지로 정상보행, 절름발이, 지팡이, 느린 보행, 허리굽은 상태에서 보행, 스스로 휠체어를 끌 때 그리고 누군가가 휠체어를 밀어줄 때 로 구성하였다. 피험자는 건강한 성인 남성 8명, 여성 2명으로 총 10명으로 구성하였다. 본 연구의 이전 실험에서, 절름발이를 오른발과 왼발을 구분하여 분류를 하고자 하였다. 하지만 비슷한 패턴과 3축 가속도센서 값의 범위가 비슷하여 구분하기 어려웠다. 이에 본 연구에서는 단일 패턴으로 설정하였다. 또한 휠체어의 경우 정확도가 낮게 나타났는데, 이는 3축 가속도 센서의 x축, y축, z축 데이터가 값이 작고, 비슷한 패턴 때문인 것으로 사료된다. 차후 연구에서는 두 패턴을 명확히 구분할 수 있는 새로운 특징점을 도출한다면 보다 높은 인식률을 얻을 수 있을 것으로 판단된다.

기존의 선행연구[6]의 결과에서는 k-NN알고리즘의 정상보행 인식률이 92%, 느린 보행이 94.1%로 나타났고, DT에서는 80.9%와 86.3%, MLP에서는 84.6%와 90.8%,

Logistic에서는 74.2%와 88.3%, NB에서는 55.7%와 61.3%로 나타났다.

본 연구에서는 k-NN알고리즘의 정상보행 인식률이 100%, 느린 보행이 100%로 나타났고, DT에서는 98.1%, 99.3%, MLP에서는 98.8%, 99%, Logistic에서는 97.5%, 99.4%, NB에서는 96.8%, 98.7%로 나타났다. 기존의 선행 연구 결과 대비 k-NN알고리즘에서는 각각 8%, 5.9%, DT에서는 17.2%, 13%, MLP에서는 14.2%, 8.2%, Logistic에서는 23.3%, 11.1%, NB에서는 41.1%, 37.4%로 인식률이 높게 나타났다. 이는 분류에 사용할 데이터의 특징점의 차이에 의해 차이가 나는 것으로 사료된다.

본 연구를 통해 얻은 결과는 향후 행동인식을 위한 효율적인 분류 알고리즘을 선택하는데 도움이 될 것이라 사료된다.

감사의 글

본 연구는 미래창조과학부 및 정보통신기술진흥센터의 ICT융합고급인력과정지원사업의 연구결과로 수행되었음 (IITP-2015-H8601-15-1009).

참고문헌

[1] Y.G. Lee, D.J. Cheon and G.W. Yoon "Telemonitoring System of Fall Detection for the Elderly" Journal of Sensor Science and Technology, Vol.20, No.6, pp.420-427, 2011.

[2] J.H. Lee, H.A. Kim and S.W. Park "Prevention of fall in the hospital" Journal of Korean Med Assoc, 58, pp.110-115, 2015.

[3] Anne Shumway-Cook, Marcia A Ciol, Jeanne Hoffman, Brian J Dudgeon, Kathryn Yorkston and Leighton Chan "Falls in the Medicare Population: Incidence, Associated Factors, and Impact on Health Care" Physical Therapy, Vol.89, No.4, pp.324-332, 2009.

[4] M.Y. Jeon, H.C. Jeong, M.A. Choe "A Study on the Elderly patients Hospitalized by the Fracture from the Fall" Journal of Korean Academy of Nursing, Vol.31, No.3, pp.443-353, 2001.

[5] Y., Nam & J.W. 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.

[6] Wu W, Dasgupta S, Ramirez EE, Peterson C, Norman GJ. "Classification accuracies of physical activities using smartphone motion sensors" J Med Internet Res. Vol.14, No.5;e130. doi: 10.2196/jmir.2208, 2012.