

라이프로그 기반 일상생활 활동유형에 대한 탐색적 연구

임호연^{*,**}, 정승은^{**}, 정치윤^{**}, 정현태^{**}

^{**}한국전자통신연구원 인공지능연구소

^{*}서울시립대학교 컴퓨터과학부

hoyeon94@uos.ac.kr, {schung, iamready, htjeong}@etri.re.kr

An Exploratory Study on Daily Activity Types based on Life-logging Data

Hoyeon Lim^{*,**}, Seungeun Chung^{**}, Chi Yoon Jeong^{**}, Hyun-Tae Jeong^{**}

^{**}Artificial Intelligence Research Lab., Electronics and Telecommunications
Research Institute

^{*}Dept. of Computer Science, University of Seoul

요 약

본 논문에서는 라이프로그 데이터를 기반으로 한 행동인식 결과로부터 일상생활의 활동유형을 분석하는 기술에 대해 제안한다. 실제 일상생활 중에 수집한 가속도 센서 데이터만을 이용하여 분석한 행동인식 결과를 정적-동적 행동으로 분류된 특징 벡터로 나타내었고, 이를 클러스터링하여 6개의 대표 활동유형으로 분류하였다. 50명의 사용자 데이터를 분석하여 정적-동적 활동의 비율에 따른 활동유형을 분류함으로써 실제 라이프로그 데이터로부터 일상생활 활동유형을 확인하였다.

1. 서론

일상생활 중에도 다양한 센서를 통해 사용자의 행동 및 활동량, 건강상태 등을 인식하는 스마트워치, 헬스케어 밴드 등 웨어러블 디바이스가 널리 보급되면서 온바디 센서 기반 행동인식 기술이 활발하게 연구되고 있다[1]. 이러한 행동인식 결과를 토대로 애플 워치(Apple Watch), 핏빗(Fitbit), 가민(Garmin) 등의 웨어러블 기기 및 서비스 플랫폼에서는 사용자의 일상생활 중 활동량 또는 운동량 등의 정보를 제공하지만, 이는 단순한 통계적인 결과만을 보여준다.

기존 연구에서는 신체 활동량 분석을 통한 운동량 파악의 필요성을 논의하고 설문을 통해 이를 수행하였으나[2], 실제 라이프로그를 기반으로 신체의 활동 정보를 수집하고 분석하는 연구는 여전히 부족한 실정이다. 따라서, 본 논문에서는 실생활에서 수집한 라이프로그 데이터를 기반으로 사용자의 일상생활 활동유형을 분석하여 분류하는 기술을 제안한다.

2장에서는 행동인식과 활동량 패턴을 분석한 관련 연구를 소개하고, 3장에서는 행동인식 기술을 활용하여 일상생활 활동유형을 분석하는 연구 방법을 기술한다. 4장에서는 연구에서 도출한 결과에 대해 고찰하고, 마지막으로 5장에서는 본 논문의 연구 결과를 정리하고 향후 연구방안을 제안한다.

2. 관련 연구

2.1. 행동인식

딥러닝 학습 방법을 이용하여 행동을 인식하는 기술에 관한 연구가 활발히 이루어지고 있다. 이는 온바디 IMU(Inertial Measurement Unit) 센서로부터 수집한 3축 가속도, 각속도, 지자계 데이터를 일정한 크기의 윈도우로 나누고, 다양한 인공신경망 구조를 통해 대표적인 일상생활 행동(ADL, Activities of Daily Living), 주로 앉기, 걷기, 뛰기, 눕기, 서기, 계단 올라가기, 계단 내려가기 등의 행동을 인식하는 방법을 연구한다. 많은 연구에서 딥러닝을 이용한 방법이 특징 추출을 기반으로 한 인식 방법보다 성능이 뛰어난 것으로 나타났다[3, 4].

2.2. 활동량 패턴 분석

사용자에게 지급한 손목 착용형 밴드를 통해 4주간 수집된 걸음 수 데이터를 분석하여 개인의 활동량 변화 패턴을 알아내고, 이를 분석하여 몇 가지 군집으로 나눈 연구가 진행되었다[5]. 위 연구는 일상생활에서 수집된 데이터를 활용하여 생활 주기(평일/주말)를 고려해 개인의 요일별 활동량 변화 패턴을 분석했다는 점에서 의의가 있지만, 운동량 데이터만을 사용했다는 점에서 한계가 있다.

3. 연구 방법

3.1. 실험 데이터 수집 및 전처리

성인남녀 50명을 대상으로 연속된 14일 동안 매일 12시간씩 일상생활에서의 라이프로그 데이터 수집 실험을 진행하였다[6,7]. 실험 참가자들은 온바디 IMU 센서 중 Empatica E4 손목밴드는 주사용 손의 반대쪽 손목에 착용하고, 4개의 metaMotion 센서는 주사용 손목, 허리, 양발목에 각각 착용하였으며, 모바일 어플리케이션을 이용하여 일상생활 중의 행동에 대한 레이블을 수시로 입력하였다. 수집한 데이터 중 분석을 위해서 총 9,866개의 레이블과 약 6,400시간 분량의 센서 데이터를 사용하였다.

실험에 사용한 E4와 metaMotion 센서의 데이터 수집 주기가 32Hz와 20Hz로 서로 다르고 시간 동기화가 되어있지 않기 때문에, 데이터 전처리를 진행하였다. 또한, 온바디 센서 특성상 상용 제품이라 하더라도 과도한 움직임에 취약하여 결측 구간 발생이 불가피하여 이를 위한 전처리가 필요하였다.

E4 센서 데이터가 측정된 시각의 metaMotion 센서 데이터의 값을 선형 보간법을 이용해 추정한다. $m(s)$ 를 측정시간 s 에서의 metaMotion 센서의 데이터로 정의한다. 만약 t 라는 시점에 E4 센서 데이터가 수집되었다면, 두 센서 데이터의 시간을 동기화하기 위해 $m(t)$ 의 값을 구해야 한다. metaMotion 센서 데이터가 α , β 시간에 수집되었고, 해당 값은 각각 $m(\alpha)$, $m(\beta)$ 이다. t 가 α 와 β 사이에 있는 시간이라면, $m(t)$ 는 다음과 같이 추정한다.

$$m(t) = \frac{(m(\beta) - m(\alpha))}{\beta - \alpha} \times (t - \alpha) + m(\alpha)$$

위의 식을 이용해, 모든 metaMotion 센서 데이터와 E4 센서 데이터의 시간을 동기화하였다.

3.2. 사용자의 행동 분류

각 센서의 3축 가속도 데이터를 n-by-n 행렬 형태의 원도우로 만들어 행동 인식기의 입력값으로 사용한다. 원도우는 약 2초에 해당하는 E4 데이터와 이에 시간 동기화된 metaMotion 센서 데이터를 포함한다. 레이블에 해당하는 센서 데이터를 CNN 기반의 네트워크 모델을 사용하여 학습하였으며[8], 마지막 softmax classifier를 통해 4가지 기본 행동(앉기, 걷기, 서기, 눕기)을 분류하였다. 사용자별로 학습된 인식 모델을 사용하여 실험일 전체 데이터에 해당하

는 행동인식 결과를 사용자별로 도출하였다.

사용자의 활동유형 분석을 위해 각 사용자의 행동인식 결과를 나타낼 특징(feature) 벡터를 정의하였다. 매일 아침 사용자가 센서를 장착하여 실험을 시작한 시점부터 10시간 동안 수집된 센서 데이터의 행동인식 결과를 특징 벡터로 표현하였다. 하루 동안의 실험 시간을 10분 단위의 구간으로 나누고, 이 단위시간 동안의 행동인식 결과를 비율로 나타낸다.

이때, 4개의 클래스로 분류한 행동을 정적(앉기와 눕기)-동적(걷기와 서기)인 2개의 활동유형으로 단순화하고, 정적-동적 활동유형의 비율을 특징값으로 사용하였다. 예를 들어, 단위시간 내에 ‘앉기’ 또는 ‘눕기’에 해당하는 행동이 10번, ‘걷기’ 또는 ‘서기’에 해당하는 행동이 20번 나타났다면, 해당 단위시간의 정적 활동의 비율은 1/3, 동적 활동의 비율은 2/3으로 표현된다. 이렇게 구한 단위시간별 활동유형 비율의 누적 합을 특징 벡터로 사용한다. n 번째 단위시간의 정적 비율을 $s(n)$, 동적 비율을 $d(n)$ 라고 정의한다면, 다음과 같은 식을 통해 $s(n)$ 과 $d(n)$ 의 누적 합 $S(n)$, $D(n)$ 을 구할 수 있다.

$$S(n) = \sum_{t=1}^{t=n} s(t)$$


$$D(n) = \sum_{t=1}^{t=n} d(t)$$

이처럼 10시간의 실험 시간을 10분 길이의 단위시간으로 구간을 나누면 60개의 구간이 생기므로, 실험일 1일은 정적-동적 누적 합에 해당하는 특징 벡터로 표현할 수 있고 이는 하루의 활동유형을 나타낸다. 이렇게 누적 합을 사용하면 서로 다른 사용자의 활동유형을 비교할 때 행동의 정확한 발생 시각보다 발생 패턴을 더 쉽게 반영할 수 있다.

3.3. 활동유형 분석

특징 벡터로 표현된 사용자의 활동유형을 스펙트럼 군집화(spectral clustering) 알고리즘을 이용하여 분류한다. 스펙트럼 군집화는 그래프 기반의 군집화 기법으로, 널리 사용되는 k-means 군집화 기법이 비선형적인 특징 벡터들의 차이를 누지 못하는 단점을 극복할 수 있는 것으로 알려진 알고리즘이다[9].

유사도 행렬(affinity matrix)로 $k=10$ 인 연결상태를 사용하는 k-nearest neighbor graph를 사용하며, 이 과정에서 유클리드 거리함수를 사용한다. 이러한 유



(그림 1) 최적의 클러스터 개수 설정을 위한 분석 결과,
(a) Gap statistic 방법: 클러스터 개수에 따른 gap value
(b) Eigen gap 방법: 인덱스에 따른 eigen gap value

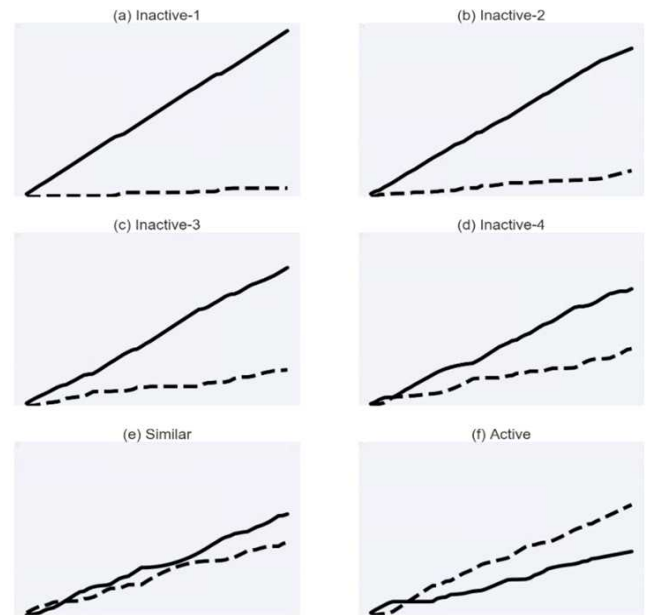
사도 행렬을 이용하여 정규화된 라플라시안 행렬 (laplacian matrix)을 만들고 고유벡터(eigen vector)와 고유값(eigen value)을 구한다. 스펙트럼 군집화 마지막 과정에 각 개체가 속한 클러스터를 라벨링하기 위해 k-means 군집화를 사용하게 되는데, 이때 사용할 고유벡터의 특징 개수는 구하고자 하는 클러스터 개수와 같게 설정한다.

클러스터의 개수를 설정하기 위해 gap statistic 방법과 eigen gap을 이용한 방법을 사용한다[10]. Gap statistic 방법은 gap이 크게 감소하는 지점의 클러스터 개수에서 가장 가까운 점을 선택하는 것으로 알려져 있다[11]. 그림 1 (a)는 데이터셋에 gap statistic을 적용했을 때 클러스터 개수에 따른 gap value를 나타낸 그래프로, 클러스터 개수가 5개와 6개 사이에서 기울기가 크게 감소하는 것을 확인할 수 있다. Eigen gap을 이용한 방법은 정렬된 고유값 간의 차이(eigen gap)가 큰 지점으로부터 클러스터의 개수를 휴리스틱하게 추측한다. 그림 1 (b)는 데이터셋으로부터 도출한 eigen gap의 값을 나타내는 그래프로, 이상의 결과를 토대로 활동유형 분류를 위한 최적의 클러스터 개수를 6개로 선택하였다.

4. 연구 결과

전체 사용자의 실험일별 특징 벡터를 6개의 클러스터로 나누고, 각 클러스터에 해당하는 6개의 대표 활동유형을 그림 2와 같이 하루 중 시간에 따른 누적 그래프로 나타내었다. 실선은 정적 활동을, 점선은 동적 활동을 나타내며, x축은 센서 장착 시점부터 단위시간의 경과를, y축은 각 시점의 활동 비율의 누적 합을 나타낸다. 따라서 그래프의 기울기를 통해 해당 시점에 어떤 활동이 많이 발생했는지 확인할 수 있다.

실험 참가자 대부분이 앉아 있는 시간이 많은 학



(그림 2) 6개의 클러스터로 분류한 활동유형 분석 결과



(그림 3) 대표 사용자의 활동유형,

(a) 동적 활동이 많은 유형, (b) 정적 활동이 많은 유형

생 혹은 직장인인 관계로 전체의 78%에 해당하는 실험일이 정적 활동이 우세한 Inactive 활동유형으로 분류되었다. 그림 2 (a) Inactive-1 유형은 정적-동적 활동의 비율 차이가 가장 큰 유형으로 정적 활동이 우세하며, (b) Inactive-2 유형은 이전 유형에 비해 낮은 시간에 조금 더 활동적인 유형이다. 그림 2 (c) Inactive-3 유형과 (d) Inactive-4 유형도 마찬가지로 정적 활동이 우세하며, 동적 활동을 나타내는 그래프가 계속 상승하는 것을 보아, 이른 시간에 많지 않지만 잦은 활동을 꾸준히 하는 것으로 보인다. 그림 2 (e) Similar 유형은 정적 활동과 동적 활동의 시간이 서로 비슷한 활동유형을 보이며, 마지막으로 (f) Active 유형은 걷거나 서 있는 동적 활동 시간이 많아 있는 정적 활동 시간보다 많은 유형으로, 이러한 유형은 평일보다는 주말이나 공휴일에 많이 나타나는 것을 확인하였다.

마지막으로, 각 사용자 별 활동유형을 레이더 차트로 나타내었다. 차트 항목은 정적(Inactive) 유형에

서부터 동적(active) 유형을 시계방향 순으로 표시하였고, 축은 각 활동유형에 해당하는 실험일 카운트를 의미한다. 그림 3은 대표 사용자 유형을 나타내는데, (a) 8번 사용자는 대부분의 실험일이 비교적 동적 활동이 우세한 Inactive-4 유형과 Active, 혹은 Similar 유형에 걸쳐 나타나는 동적 활동유형을 보이는 반면, (b) 117번 사용자는 거의 모든 실험일이 정적 활동이 우세한 Inactive-1과 Inactive-2 유형에 해당하는 정적인 활동유형을 보이는 것을 확인하였다.

5. 결론

본 논문에서는 실제 일상생활에서 수집한 가속도 센서 데이터만을 이용하여 분석한 행동인식 결과를 정적-동적 행동으로 분류된 특징 벡터로 나타내었고, 이를 스펙트럼 군집화 방법을 사용하여 6개의 일상생활 활동유형으로 분류하였다. 이를 위해 이론적으로 검증된 gap statistic 및 eigen gap 방법을 이용하여 최적의 클러스터 개수를 도출하였고, 50명의 사용자의 일상생활 활동유형을 분석하였다. 이러한 분석 결과는 개인의 활동유형 및 생활주기를 파악하고 피드백하는 데 사용될 수 있다.

본 논문에서 사용된 3축 가속도 센서 데이터 외에도 향후 3축 각속도 센서 데이터와 자자기 센서 데이터, 심박수 데이터나 위치 정보 등 다양한 종류의 라이프로그 데이터를 활용한다면, 다차원의 분석이 가능할 것으로 생각된다.

감사의 글

본 연구는 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음. [20ZS1100, 자율성장형 복합인공지능 원천기술 연구]

참고문헌

[1] Zawar Hussain, Michael Sheng, Wei Emma Zhang, "Different Approaches for Human Activity Recognition: A Survey", arXiv, 2019
 [2] 양윤준, 윤영숙, 이연숙, 오상우, "2001 국민건강영양조사에 의한 우리나라 성인의 신체활동도.", 대한가정의학회지, 26권, 1호, 22-30, 2005
 [3] Ming Zeng, Le T. Nguyen, Bo Yu, Ole J. Mengshoel, Jiang Zhu, Pang Wu, Joy Zhang, "Convolutional Neural Networks for Human Activity Recognition using Mobile Sensors", 6th

International Conference on Mobile Computing, Applications and Services(MobiCASE), Austin, TX, USA, 2014, 197-205
 [4] 김정균, 이강복, 홍상기, "깊은 신경망을 이용한 IMU센서 기반 행동인식", 한국정보과학회 2016년 동계학술대회 논문집, 532-534, 2016
 [5] 김병준, 김유정, 이중식, "웨어러블 디바이스 데이터를 통해 분석한 요일별 활동량 패턴 유형에 대한 탐색적 연구", 한국HCI학회 학술대회, 한국, 2018, 460-464
 [6] Seungeun Chung, Inyoung Hwang, Jiyoun Lim, Hyun-Tae Jeong, "Finding Points-of-Interest (PoIs) from Life-logging and Location Trace Data," International Conference on Information and Communication Technology Convergence (ICTC), Jeju Island, Korea (South), 2019, 1300-1303
 [7] Jiyoun Lim, Seungeun Chung, Kyoung Ju Noh, Gague Kim, Hyun-Tae Jeong, "An empirical study on finding experience sampling parameters to explain sleep quality based on dimension reduction," International Conference on Information and Communication Technology Convergence (ICTC), Jeju Island, Korea (South), 2019, 1295-1299
 [8] Seungeun Chung, Jiyoun Lim, Kyoung Ju Noh, Gague Kim, Hyun-Tae Jeong, "Sensor Data Acquisition and Multimodal Sensor Fusion for Human Activity Recognition Using Deep Learning," Sensors 2019, 19, 1716
 [9] Inderjit S. Dhillon, Yuqiang Guan, Brian Kulis, "Kernel k-means: spectral clustering and normalized cuts," Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining, Seattle WA USA, 2004, 551 - 556
 [10] Ulrike von Luxburg, "A Tutorial on Spectral Clustering", Statistics and Computing, 17권, 4호, 395-416, 2007
 [11] Tibshirani, Robert & Walther, Guenther & Hastie, Trevor, "Estimating the Number of Clusters in a Data Set Via the Gap Statistic," Journal of the Royal Statistical Society Series B, 63권, 2호, 411-423, 2001