

A Study on Meal Time Estimation and Eating Behavior Recognition Considering Movement Using Wrist-Worn Accelerometer with Its Frequency

Kyeong Chan Park[†] · Sun-Taag Choe^{††} · We-duke Cho^{†††}

ABSTRACT

In this paper, we propose a method for recognizing eating behavior with almost no motion acceleration. First, by using the acceleration of gravity acting on the wrist direction, we calculate the angle between the gravity and the wrist direction. After that, detect wrist reciprocating motion when peak and vally exist in specific angle band. And then, when accumulate the number of wrist reciprocating motion occurrences are up to 10, then regard as the meal time 5 minutes before the detection time. Also, estimate the meal time only if its duration is more than 7 minutes. Using the data of 2128 minutes, which was collected from four graduate student, the result of the meal time estimation shows 95.63% accuracy.

Keywords : Eating, Accelerometer, Activity Recognition

손목 움직임과 동작 빈도를 고려한 손목형 가속도계의 식사 행위 및 식사 시간 추론 기법

박 경 찬[†] · 최 선 탁^{††} · 조 위 덕^{†††}

요 약

본 논문에서는 손목형 가속도계를 이용하여 운동 가속도가 거의 없는 식사 행동을 인식하기 위한 방법을 제안한다. 먼저 손목 방향에 작용하는 중력 가속도를 이용하여 중력 방향과 손목 방향 간의 각도를 구하고, 특정 각도 영역에서 첨두값과 첨미값이 존재하는 경우 손목이 왕복하는 동작을 검출한다. 손목 왕복 동작 발생 횟수를 누적하여 그 횟수가 10회 이상일 경우 검출 시점으로 5분 전까지 식사 시간으로 간주하며, 그 지속시간이 7분 이상인 경우에만 식사 시간으로 추론한다. 대학원생 4명으로부터 수집한 2128분 데이터를 통해 식사 시간을 추론한 결과 95.63%의 정확도를 보인다.

키워드 : 식사, 가속도계, 행동 인식

1. 서 론

WHO의 보고에 의하면 2012년 한 해에 5천 6백만 명이 사망하였으며, 그 중 68%에 달하는 3천 8백만 명이 생활습관으로 사망하였다[1]. 이와 같이 전 세계적으로 높은 사망률

* 본 연구는 한국연구재단의 도약연구(전략 X-연구) "IoT 센서와 빅데이터를 사용한 나쁜습관과 실수 자동인지 및 개선예측서비스 개발" 과제의 연구 결과로 수행되었음.

** 이 논문은 2016년도 한국정보처리학회 춘계학술발표대회에서 '중력 방향과 손목 방향간의 각도를 이용한 손목형 활동량계의 흡연/식사 시간 추론에 대한 연구'의 제목으로 발표된 논문을 확장한 것임.

[†] 준 회 원 : 아주대학교 전자공학과 석사과정
^{††} 준 회 원 : 아주대학교 전자공학과 석·박사통합과정

^{†††} 종신회원 : 아주대학교 전자공학과 교수

Manuscript Received : July 1, 2016

First Revision : August 31, 2016

Accepted : September 7, 2016

* Corresponding Author : We-duke Cho(wedukecho@gmail.com)

을 보이는 생활습관병은 캐나다의 라론드 보고서에 따르면 발병 요인으로 유전이 10%, 환경이 10%, 의료가 10%, 나머지 60%는 생활습관에서 발생한다고 하였다[2]. 즉 흡연, 음주, 신체활동, 식생활 등의 생활습관이 생활습관병을 결정하는 주요 요인으로 작용하고 있다는 뜻이다. 이 중 식생활은 직접적으로 건강뿐만 아니라 간접적으로 업무 수행 능력이나 집중력에도 관련이 있다. 공복 시에 찾아오는 스트레스는 뇌의 판단력을 떨어뜨릴 수 있고[3], 기억력과 주의력도 떨어뜨린다[4]. 불규칙한 식생활이 건강을 악화시키고 피로와 집중력 저하를 유발하여 업무 효율성을 저하시키는 등 개인적, 사회적으로 문제가 되기 때문에 식생활을 체계적으로 관리하는 것이 중요하다. 하지만 보건복지부의 국민건강영양조사에 따르면 2014년 기준 10대의 아침식사 결식률이 31%, 20대의 아침식사 결식률이 41%나 되는 것으로 조사되었다[5].

2. 관련 연구

기존에는 식생활을 개선하기 위해 전문가의 체계적인 관리를 받거나, 개인이 직접 기록하여 관리하고자 하였다. 하지만 이러한 방식들은 번거로울뿐더러 기억과 주관에 의존하기 때문에 정확도가 떨어진다는 단점이 있다. 이러한 문제를 해결하기 위해 IT 기술을 이용하여 사용자의 움직임을 자동으로 기록하고, 이를 바탕으로 행동을 인식하는 방법이 제안되었다[6-12]. 대표적인 방법으로 영상을 이용하여 사용자의 행동을 기록하고, 기록한 영상으로부터 사용자의 행동을 인식하는 방법이 있다[6]. 하지만 영상을 이용하는 경우 카메라, 캠코더와 같은 영상 기기가 있어야 하고, 한정된 공간에서만 행동 인식이 가능하다는 단점이 있어 공간의 제약 없이 사용자의 행동을 인식하기 위해 센서를 사용한 연구가 진행되었다. 센서를 이용한 행동 인식은 센서의 수와 종류에 따라 크게 세 가지로 나눌 수 있다. 첫 번째는 가속도 센서, 자이로 센서, 지자기 센서 등 다종의 센서를 이용하여 움직임을 기록하여 행동을 인식하는 방법으로, 행동 인식의 정확도가 높다는 장점이 있지만 배터리 소모량이 많아 일상생활에서 사용하기 어렵다는 단점이 있다[7]. 두 번째는 다중 가속도 센서를 가슴, 복부, 허리, 바지주머니와 같이 신체 여러 부위에 착용하고 행동을 인식하는 방법으로, 다종 센서와 마찬가지로 행동 인식의 정확도가 높지만 여러 센서를 착용해야 하므로 사용자의 불편함을 야기한다[8]. 마지막으로 단일 가속도 센서를 이용하는 방법은 정확도가 조금 떨어진다는 단점이 있지만 배터리 소모량이 적고 사용자가 불편함을 느끼지 않아 일상생활 데이터를 수집하기에 적합하다[9].

단일 가속도 센서는 착용 위치에 따라 인식률이 달라지는 문제가 있기에 어느 위치가 다양한 행동을 높은 정확도로 인식할 수 있는지에 대한 연구가 있었으며, 손목이 높은 정확도로 행동을 인식함을 보였다[10]. 단일 센서를 이용해 행동 인식을 하는 방법은 크게 세 단계로 나눌 수 있다. 먼저 신호에서 잡음을 제거하기 위한 전처리 과정이 있다. 다음으로 전처리된 신호로부터 신호의 특징을 추출하는 과정이고, 이를 분류 모델에 적용하여 행동을 인식하는 과정이다.

기존 연구에서는 주로 다양한 특징들을 사용하고 여러 분류 모델을 결합함으로써 인식률을 높이는 데 주력해 왔다 [9-12]. Saisakul Chernbumroong은 손목형 가속도계를 이용하여 행동을 인식하기 위해 9종류, 13개의 특징을 사용하였고 2가지의 분류기를 사용하여 성능을 비교하였다[9]. Uwe Maurer은 10종류, 40개의 특징을 사용하여 4가지 분류기 성능을 비교한 결과 인식률이 높고 연산강도가 낮은 의사결정 트리를 사용하였다[10]. Davide Anguita은 17종류, 561개의 특징을 Support Vector Machine(SVM) 분류 모델을 이용하여 행동을 인식하였고[11], Minh Nguyen은 4종류의 특징을 사용하고 6가지 분류기의 성능을 비교하였다. 또 분류기 간의 결합을 통해 인식률을 높일 수 있음을 보였다[12]. 사용된 특징들을 정리하면 다음의 Table 1과 같다.

Table 1. Summary of Feature for Acceleration Signal

Domain	Features	Reference
Time domain	Mean, Standard Deviation	[9-12]
	Minimum	[9][11]
	Maximum	[11]
	Variance	[9-10]
	Interquartile range	[10-11]
	Root Mean Square	[10]
	Cumulative Histogram	[10]
	n'th Percentile	[10]
	Mean Absolute Deviation	[10-11]
	correlation between axes difference	[9][11-12]
	Zero Crossing Rate	[10]
	Mean Crossing Rate	[10]
Frequency domain	Spectral Entropy, Spectral Energy	[9][12]
	Skewness, Kurtosis	[11]

Table 1에 보이는 바와 같이 기존 행동 인식에 대한 연구들은 시간 영역과 주파수 영역에서 특징을 추출하였으며, 평균(Mean), 표준편차(Standard Deviation)와 같은 통계적 특징과 췌도(Kurtosis)와 같은 구조적 특징을 사용하였다. 분류 모델의 경우 추출한 특징을 여러 모델에 사용하여 가장 높은 인식률을 보이는 모델을 선택하거나, 모델 간의 결합을 통해 인식률을 높이기도 한다. Table 2는 사용된 분류 모델을 나타낸다.

Table 2. Classification Method Used by Activity Recognition

Type	Classifier	Reference
Decision Tree	C4.5	[9-10][12]
Bayesian	Naive Bayes	[10][12]
	Bayesian Network	[10]
Instance Based	K-Nearest Neighbor	[10][12]
Neural Network	Artificial Neural Network	[9][12]
Domain Transform	Support Vector Machine	[11-12]
Markov Model	Random Forest	[12]

기존 연구에서 사용된 알고리즘들은 훈련 데이터를 학습하는 과정에서 과적합 문제가 발생할 수 있다. 과적합 문제는 두 가지 종류가 있는데, 첫 번째가 훈련 데이터가 적어서 데이터로부터 추출한 특징들이 편향되어 발생하는 경우이고, 두 번째가 많은 특징들로 인해 행동 인지에 불필요한 특징까지 학습하여 모델이 과도하게 조율되어 발생하는 경우이다. 이러한 문제를 해결하기 위해 논리적 원리를 기반으로 특징을 추출하고 분류 모델을 설계하는 방법이 등장하였다[13-14]. Sen Zhang은 팔꿈치를 중심점으로 팔의 움직임을 물리적으로 모델링한 뒤 확장 칼만 필터를 적용하여 오일러 각과 각속도를 특징으로 추출하고 식사 행동을 검출하였다[13]. Raul I. Ramos-Garcia는 식사 시 발생하는 동작

을 5가지로 나누고, 각 동작 간에 순차적 관계가 있다는 것에 착안점을 두어 은닉 마코브 모델(Hidden Markov Model, HMM)을 이용하여 전이 확률을 구하였다[14]. 이러한 방법들은 한정된 상황의 물리적인 움직임을 모델링하였기 때문에 훈련 데이터가 편향될 가능성이 적고 불필요한 특징을 걸러낼 수 있기 때문에 기존 행동 인식 알고리즘에 비해 적은 특징, 적은 학습 데이터를 사용함에도 불구하고 인식률을 높일 수 있다는 장점이 있다.

하지만 새로운 행동을 검출하기 위해서는 동작 모델을 새롭게 정의하거나 구성 동작들을 새로 설정해야 하는 등 절차가 복잡하여 범용성이 떨어진다는 단점이 있다.

본 논문에서는 순목형 가속도계를 이용하여 손목 방향과 중력 방향의 사이 각도 신호를 산출하고, 이에 첨두값 영역 검출 기법을 적용하여 식사 행동을 검출한다. 그리고 동작의 빈도와 지속시간을 고려하여 식사 시간을 추론한다. 식사 행동은 동작의 속도가 빠르지 않고, 특정 시간동안 일정한 범위의 각도 내에서 손목 움직임이 반복된다. 이를 이용하여 일정 범위의 각도 내에서 첨두값과 첨미값이 검출되는 경우 식사로 인식한다. 이 방법을 이용하면 새로운 행동을 인식하기 위해 기준에 구성한 모델을 수정하는 복잡한 과정을 거치지 않고 첨두값 영역을 조절함으로써 간단하게 손목 행동을 인식할 수 있다는 장점이 있다. 본 논문에서 제안하는 방법은 첨두값 영역의 조절을 통해 흡연이나 머리를 빗는 행동 등과 같은 운동 가속도 성분이 없고 불규칙적인 행동들을 인식하는 데 적용될 수 있다.

3장에서는 데이터 수집 방법과 수집된 신호를 가공하는 방법에 대해 설명한다. 4장에서는 제안하는 식사 시간 추론 알고리즘에 대해서 논의하고, 5장에서는 실험 방법을 설명하고 알고리즘의 성능을 평가한다. 그리고 마지막 장에서 결과에 대해 논의한다.

3. 데이터 수집 방법

신호 수집을 위해 가속도계를 주로 사용하는 손의 손목에 착용하며, 착용 시 x축이 손끝을 향하도록 착용하여 신호를 수집한다. 사용한 가속도계는 10bit의 분해능을 가지며, 최대 진폭은 $\pm 8g$, 수집 주기는 32Hz이다. 수집한 데이터는 가속도계에 내장된 microSD카드에 저장되며, 이를 PC로 옮겨 분석한다.

센서는 착용 위치나 방향에 따라 중력을 받는 센서축이 바뀌기 때문에 센서 착용 방향에 상관없이 분석할 수 있도록 신호를 보정한다.

$$\theta = \sin^{-1} \left(\frac{x_{ini}}{\sqrt{x_{ini}^2 + y_{ini}^2}} \right) \quad (1)$$

$$\rho = \sin^{-1} \left(\frac{y_{ini}}{\sqrt{x_{ini}^2 + y_{ini}^2 + z_{ini}^2}} \right)$$

$$\begin{bmatrix} -\cos\theta & 0 & -\sin\theta \\ -\sin\theta \sin\rho & \cos\rho & -\cos\theta \sin\rho \\ \sin\theta \cos\rho & \sin\rho & \cos\theta \sin\rho \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} X^\dagger \\ Y^\dagger \\ Z^\dagger \end{bmatrix} \quad (2)$$

$$W = Z^\dagger$$

Equation (1)에서 $x_{ini}, y_{ini}, z_{ini}$ 는 손끝을 지면으로 향했을 때 센서의 출력값이고, θ 와 ρ 는 손의 방향과 중력 방향 사이의 각도이다. Equation (2)에서 X, Y, Z 는 보정되기 전 3축 가속도 신호이고 $X^\dagger, Y^\dagger, Z^\dagger$ 는 보정된 가속도 신호를 의미한다. 위 과정을 거치면 Fig. 1과 같이 손끝을 지면으로 향했을 때 센서의 Z축이 중력 가속도 방향과 일치하도록 보정되어 손목 방향이 된다.

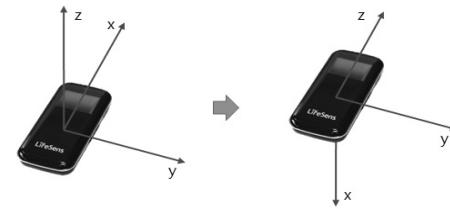


Fig. 1. Accelerometer Calibration

운동 가속도가 없는 경우, 손목 방향의 가속도 값은 삼각 함수 cosine과 역함수 관계이다. Fig. 2와 3은 손목 방향과 중력 방향 간에 손목 각도가 어떻게 나타나는지를 보여준다.

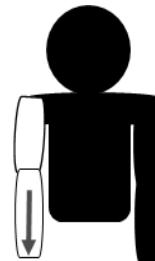


Fig. 2. Wrist Direction

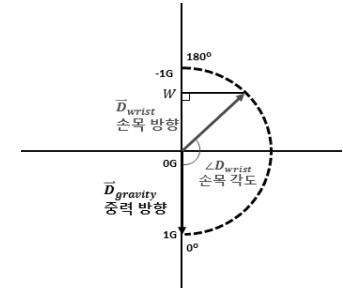


Fig. 3. Wrist Direction Angle

cosine 역함수의 정의역은 $[-1,1]$ 이므로 가속도 단위를 갖는 손목 방향 성분의 단위를 조정해야 한다.

$$\angle D_{wrist} = \cos^{-1} \left(\frac{W}{2^{Res}/R} \right) \quad (3)$$

W : 손목 방향 센서 출력값, Res : 해상도, R : 센서 측정 범위 크기

$$\angle D_{wrist} = \cos^{-1} \left(\frac{W}{9.8} \right) \quad (4)$$

W : 손목 방향 가속도 신호(m/s^2)

Equation (3)은 센서의 해상도 비트값과 센서의 측정 범위를 알고 있을 때 3축 가속도 신호를 손목 방향과 중력 방

향의 사이 각도로 바꾸는 식이고, Equation (4)는 가속도 신호가 m/s^2 단위로 출력되는 경우에 사용하는 식이다. 본 논문에서 사용한 가속도 센서는 10bit 해상도를 갖는 디지털 센서이며, 측정 범위는 $\pm 8g$ 이다. 따라서 Equation (3)을 사용하여 손목 방향의 가속도 값을 각도로 변환한다.

4. 식사 시간 추론 알고리즘

4.1 신호 전처리

식사 신호는 여러 가지 동작이 혼재되어 있어 신호의 특징을 찾기 힘들다. 하지만 식사 시 반드시 나타나는 행동이 있는데 음식물을 집어 입으로 가져간 후 테이블 위로 손을 내리는 행동이다. 이 손목의 왕복 행동은 단발적으로 나타나며, 한 번의 움직임이 발생하고 다음 움직임이 나타나기 까지 최소 2초 이상의 시간 간격이 존재한다. 따라서 주기적 행동을 제거하고 단발성 행동 신호만을 남기기 위해 표본화율(Sampling rate)은 32, 차수는 64, 차단 주파수는 0.5, 해밍 윈도우(Hamming Window)를 사용하여 설계한 FIR 저역통과필터를 신호에 적용하였다.

Fig. 4는 대표적인 주기적 행동인 걷기, 달리기 신호와 식사 신호를 나열한 그래프이다. 설계한 저역통과필터를 거치면 걷기와 달리기 신호가 제거되고 식사 신호는 그대로 남는 것을 알 수 있다.

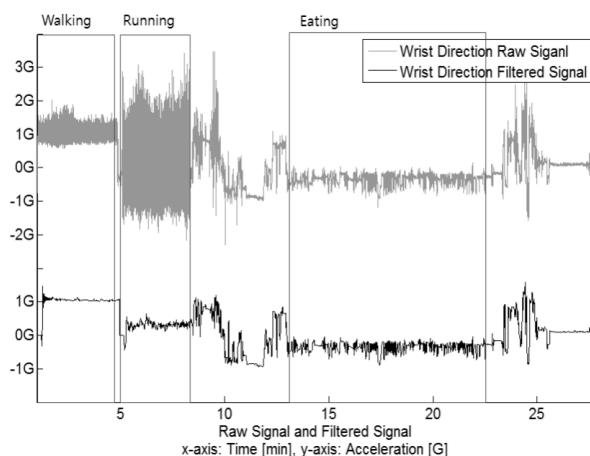


Fig. 4. Wrist Direction Raw Signal and Filtered Signal

4.2 식사 행동 검출

1) 식사 행동의 정의

식사 시간 동안 발생하는 손목 동작은 크게 두 종류로 나눌 수 있다. 첫 번째는 식기로부터 입으로 음식물을 가져가 먹은 후 테이블로 손을 내리는 동작, 두 번째는 반찬을 집어 먹은 후 테이블로 손을 내리는 동작이다. 이 두 동작은 손목이 테이블에서 입까지 왕복하는 동작이라는 공통점이 있다. 이를 손목 왕복 동작이라고 하며, 얼굴을 만지거나, 안

경을 올리는 행동, 혹은 머리를 긁는 등 식사뿐만 아니라 일상생활에서도 나타날 수 있다.

하지만 식사 행동은 특정 시간 동안 손목이 왕복하는 동작이 반복해서 발생하게 된다. 따라서 손목 왕복 동작의 발생 횟수를 누적하여 일정 횟수 이상인 경우, 그 시점 이후부터 발생하는 손목 왕복 동작을 식사 행동이라고 정의한다.

2) 첨두치 영역을 이용한 식사 행동 검출

식사 행동은 기준의 다른 행동들과 달리 불규칙적이고 단발적으로 동작이 발생한다. 하지만 식사 행동은 그 움직임의 범위가 한정되어 있다.

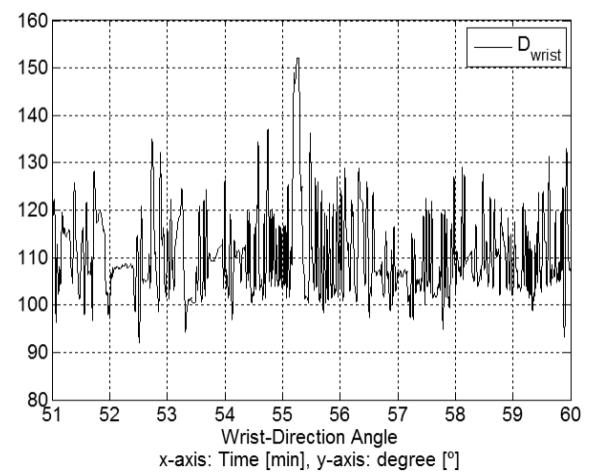


Fig. 5. Wrist Reciprocating Motion When Using Chopstick

Fig. 5는 젓가락을 사용한 식사 신호를 손목 각도로 변환한 그림이다. 식사 행동에서 나타나는 손목 왕복 동작의 각도를 보면 $90\sim160^\circ$ 사이에서 발생한다. 멀리 있는 반찬을 집는 경우에는 80° 까지 각도가 내려가기 때문에 $80\sim160^\circ$ 가 손목 왕복 동작의 움직임 범위가 된다. 이를 첨두값 영역 검출 기법을 사용하여 검출한다.

손목 왕복 동작은 $80\sim160^\circ$ 사이에 첨두값과 첨미값이 나타나게 된다. 첨두값과 첨미값을 정확히 검출하기 위해 3° 간격으로 양자화 과정을 거쳐 리플을 제거한다. 이후 아래쪽 영역에 첨미값이 두 개, 위쪽 영역에 첨두값이 하나가 존재한다면 이를 손목 왕복 동작으로 검출한다. 손목 왕복 동작의 첨두값 영역은 위쪽 영역이 $125\sim160^\circ$, 아래쪽 영역이 $80\sim120^\circ$ 가 된다. Fig. 6은 손목 왕복 동작 신호와 첨두값 영역을 나타낸 것으로 v_f , v_s 는 첨미값을, p_f 는 첨두값을 의미한다.

몸을 숙여 식사를 하거나, 그릇을 들고 식사를 하는 경우 각도의 변화가 작아져 첨두값이 나타나는 영역이 바뀔 수 있다. 따라서 위쪽 영역을 $110\sim160^\circ$, 아래쪽 영역을 $105\sim160^\circ$ 로 바꾸어 손목 왕복 동작을 한 번 더 검출한다. 그리고 어느 한 쪽이라도 손목 왕복 동작이 검출되는 경우 손목 왕복 동작으로 검출한다.

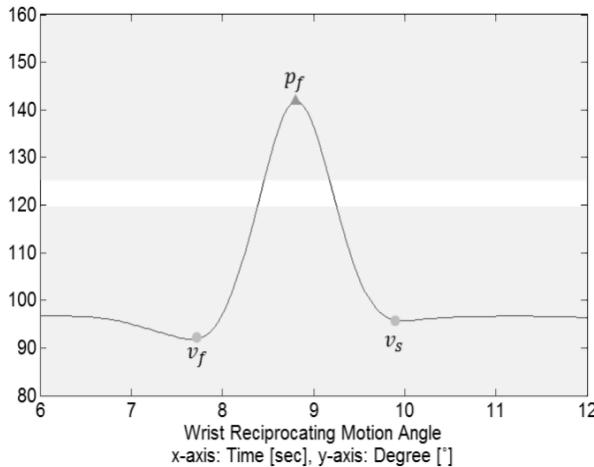


Fig. 6. The Method of Wrist Reciprocating Motion Detection Using Peak Band Detection

검출한 이후에는 5분 간 손목 왕복 동작의 발생 횟수를 누적하여 그 횟수가 10회 이상이 되는 시점 이후부터 발생하는 손목 왕복 동작을 식사 행동으로 인식한다. Fig. 7은 수집한 실험 데이터 중 일부로, 첨두값 영역 검출 기법을 이용하여 손목 왕복 동작을 검출하고, 그 횟수를 누적한 결과이다. 약 990분부터 1010분까지가 실제 식사 시간이며, 식사 시간동안 손목 왕복 동작이 지속적으로 나타나며, 이를 5분 간 누적하여 그 횟수가 10회 넘었을 때, 이를 식사 행동으로 인식한다. 식사 시간 외에도 손목 왕복 동작이 산발적으로 검출되는 부분들이 있는데 이는 얼굴이나 머리를 만지거나 물을 마시는 행동 등으로 인해 나타난다.

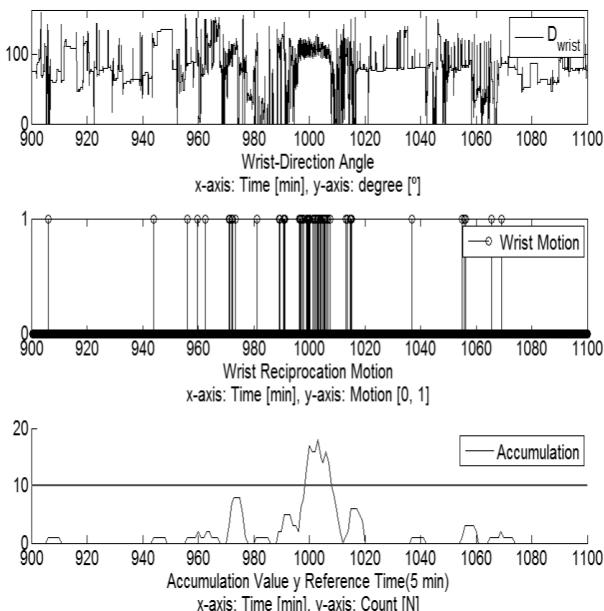


Fig. 7. Result of Wrist Reciprocating Motion Detection and Accumulation

4.3 식사 시간 추론

식사 시간 추론 과정은 식사 시간 인식률을 높이기 위한 후처리 과정으로 두 단계로 나뉜다. 첫 번째 단계는 검출 시점 이전 5분까지를 식사 시간이라고 인식하는 것이다. 식사 행동은 특정 시간 동안 손목 왕복 행동의 발생 횟수를 누적하여 일정 횟수 이상인 경우, 그 시점 이후부터 발생하는 손목 왕복 행동이라고 앞서 정의하였다. 이를 통해 검출한 식사 행동이 발생한 시간은 식사 시간이라고 할 수 있다. 식사 행동을 검출할 때 5분 간 손목 왕복 행동을 누적한 후 그 이후부터 식사 행동이라고 하였기 때문에 검출 시점 이전 5분까지 식사 시간이라고 간주한다.

Fig. 8은 수집한 실험 데이터 중 일부로, 5분 간 손목 왕복 행동을 누적한 그래프이다. 두 번째 그래프는 분당 식사 행동의 발생 유무를 의미하는데, 이를 네 번째 실제 식사 그래프와 보면 많은 차이가 나는 것을 알 수 있다. 또한 두 번째 식사 그래프를 보면 5분 간 손목 왕복 동작이 10회를 넘지 않는 경우가 있는데, 이는 식사 속도가 느리고 중간에 잠시 식사를 쉬었다가 재개한 상황이다. 세 번째 그래프는 식사 행동 검출 시점 이전 5분까지를 식사 시간으로 추론하는 과정을 적용한 결과로, 실제 식사 시간과 유사해진 것을 확인할 수 있다.

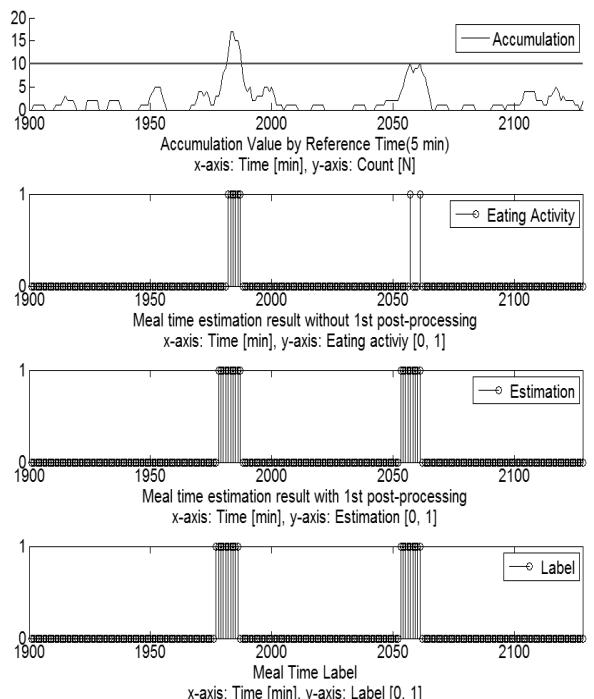
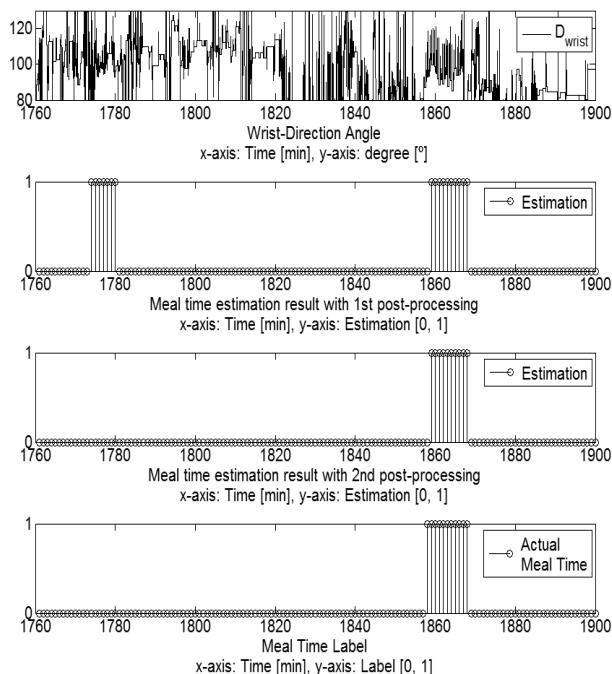


Fig. 8. 1st Post-Processing Result and Actual Meal Time

두 번째 단계는 식사 지속 시간이 7분 이상인 경우만 식사 시간이라고 인식하는 것이다. 이는 얼굴이나 머리를 만지거나 혹은 물을 마시는 손목 왕복 운동이 짧은 시간동안 많은 횟수가 누적되어 식사라고 판단되는 경우가 있기 때문이다.

Fig. 9는 수집한 실험 데이터 중 일부로, 식사 시간이 아닌 데 식사 시간이라고 검출된 경우이다. 첫 번째 그래프는 손목 각도 신호로, 1780분 근처와 1860분 근처 그래프를 비교해 보면 1780분 근처에서 나타난 신호가 식사 시간이 아님을 알 수 있다. 두 번째 그래프는 1차 후처리 과정이 적용된 결과로, 네 번째 실제 식사 그래프와 비교해 보았을 때 식사 시간이 아닌데 식사 시간이라고 인식 결과가 나타난 것을 볼 수 있다. 세 번째 그래프는 2차 후처리 과정을 거친 결과로, 식사 시간이 아닌 부분이 제거되는 것을 확인할 수 있다.

Fig. 9. 2nd Post-Processing Result and Actual Meal Time

5. 실험 및 성능평가

5.1 실험

알고리즘의 성능을 평가하기 위해서 4명의 대학원생으로부터 2일간 식사 데이터를 수집하였다. 식사는 젓가락만을 사용하여 식사를 2회, 숟가락만을 사용하여 식사를 1회 하였으며, 식사 시작 시각과 식사 종료 시각을 기록하였다. 식사 중에는 스마트폰을 사용하거나 머리를 긁는 등의 식사 외적인 행동을 배제하여 식사만 할 수 있도록 하였다. 식사 전 약 1시간, 식사 후 약 3시간 동안 데이터를 연속적으로 수집하여 식사 외의 행동도 함께 수집하도록 하였다.

5.2 성능 평가

기기의 오류로 인하여 누락된 데이터를 제외하고 총 2128분의 데이터를 검증에 사용하였으며, 그 중 식사는 131분이고 일상행동은 1997분이다.

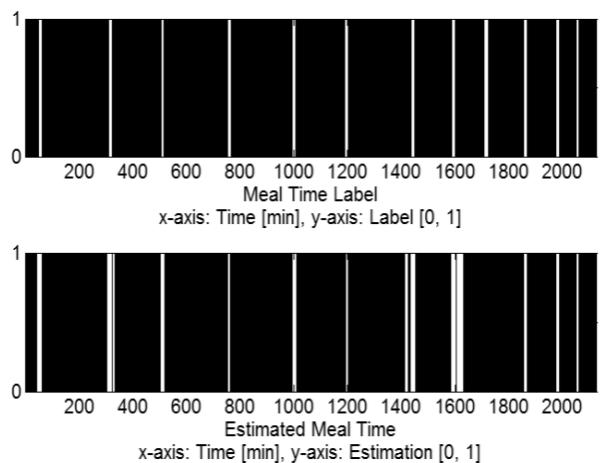


Fig. 10. Actual Meal Time and Estimated Meal Time

Table 3. Confusion Matrix of Proposal Algorithm

		Estimated Class		
		Meal Time	Non Meal Time	
Actual Class	Meal Time	111	20	84.73% (TPR)
	Non Meal Time	73	1924	96.35% (TNR)
		60.33% (PPV)	98.97% (NPV)	95.63% (Accuracy)

Fig. 10은 라벨 데이터와 제안하는 알고리즘을 통해 추론한 식사 시간을 비교한 그림이다. 7번째(약 1400분)부터 9번째(약 1700분) 식사 시간을 추론하는 데 오차가 발생한 것을 확인할 수 있다. 7번째 식사와 8번째 식사는 식사 전후로 물을 마시는 동작이 식사와 유사하여 검출된 결과이다. 9번째 식사는 식사 시 몸을 숙여 손목 왕복 동작의 각도 변화가 매우 적어 제대로 검출되지 않았다.

Table 3은 제안하는 알고리즘의 성능 평가 결과이다. 실제 식사 시간을 식사 시간으로 추론한 경우가 111분, 실제 식사 시간을 식사 시간이 아니라고 추론한 경우가 20분, 실제 식사 시간이 아닌데 식사 시간이라고 추론한 경우가 73분, 실제 식사 시간이 아닌데 식사 시간이라고 추론한 경우가 1924분이다. 정밀도(Positive Predictive Value, PPV)는 60.33%, 재현율(True Positive Rate, TPR)은 84.73%이고, True Negative Rate(TNR)은 96.35%, Negative Predictive Value는 98.97%이다.

6. 결 론

본 논문은 가속도값을 중력 방향과 손목 방향 간의 각도로 변환하고, 이를 점두값 영역 검출 기법을 사용하여 식사 행동을 인식하고 식사 시간을 추론하는 방법을 제안하였다.

대학원생 4명으로부터 수집된 2128분 데이터에 제안하는 방법을 적용한 결과 95.63%의 정확도로 식사 시간을 판단할 수 있었다.

하지만 Table 3에서 정밀도(PPV)의 값이 60.33%로 낮게 나온 것을 볼 수 있는데, 이는 식사 중이 아님에도 식사라고 추론한 시간이 많이 나타났기 때문이다. 이와 같은 결과가 나온 이유는 첫 번째로 식사와 물을 마시거나 얼굴을 만지는 행동과 같이 식사와 유사한 신호를 식사라고 판단했기 때문이고, 두 번째로 식사 시간 추론 과정에서 검출 시점으로부터 5분 전까지를 식사 시간일 가능성이 있는 영역이라고 간주하여 실제 식사 시간보다 더 긴 시간을 식사라고 판단한 부분이 발생했기 때문이다.

본 논문에서 제안하는 방법은 식사 시간이 7분 미만인 경우 식사 시간을 검출하지 못한다는 단점이 있다. 또한 책상의 높이나 식사 시의 자세에 따라서 순목 각도의 변화 영역이 다르게 나타나 인식률이 떨어질 수 있다. 차후 연구로는 순목 각도의 변화 영역이 다르게 나타나더라도 이를 인식할 수 있는 알고리즘을 개발할 것이다.

References

- [1] WHO, "Global status report on noncommunicable diseases 2014," World Health Organization, 2014.
- [2] M. Lalonde, New perspective on the health of Canadians a working document, Minister of Supply and Services, 1981.
- [3] Mark T. McAuley et al., "A mathematical model of aging-related and cortisol induced hippocampal dysfunction," *BMC Neuroscience*, Vol.10, No.1, p.1, 2009.
- [4] A. Peters, "The selfish brain: Competition for energy resources," *American Journal of Human Biology*, Vol.23, No.1, pp.29–34, 2011.
- [5] Ministry of Health & Welfare, Breakfast intake rate trend : Sex, over 1 year old [Internet], http://kosis.kr/statHtml/statHtmldo?orgId=117&tblId=DT_11702_N033&conn_path=I2.
- [6] R. Poppe, "A survey on vision-based human action recognition," *Image and Vision Computing*, Vol.28, No.6, pp.976–990, 2010.
- [7] M. Zhang, and A. A. Sawchuk, "A feature selection-based framework for human activity recognition using wearable multimodal sensors," *Proceedings of the 6th International Conference on Body Area Networks*, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), pp.92–98, 2011.
- [8] L. Gao, A. K. Bourke, and J. Nelson, "Evaluation of accelerometer based multi-sensor versus single-sensor activity recognition systems," *Medical Engineering & Physics*, Vol.36, No.6, pp.779–785, 2014.
- [9] S. Chernbumroong, A. S. Atkins, and H. Yu, "Activity classification using a single wrist-worn accelerometer," *Software, Knowledge Information, Industrial Management and Applications (SKIMA), 2011 5th International Conference on*, IEEE, pp.1–6, 2011.
- [10] U. Maurer et al., "Activity recognition and monitoring using multiple sensors on different body positions," *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*, IEEE, 2006.
- [11] D. Anguita et al., "A Public Domain Dataset for Human Activity Recognition using Smartphones," *ESANN*, 2013.
- [12] M. Nguyen, L. Fan, and C. Shahabi, "Activity Recognition Using Wrist-Worn Sensors for Human Performance Evaluation," *2015 IEEE International Conference on Data Mining Workshop (ICDMW)*, IEEE, 2015.
- [13] S. Zhang et al., "Detection of activities by wireless sensors for daily life surveillance: eating and drinking," *Sensors*, Vol.9, No.3, pp.1499–1517, 2009.
- [14] R. I. Ramos-Garcia et al., "Improving the recognition of eating gestures using intergesture sequential dependencies," *IEEE Journal of Biomedical and Health Informatics*, Vol.19, No.3, pp.825–831, 2015.



박 경 찬

e-mail : bluepark16@gmail.com
2015년 아주대학교 전자공학과(학사)
2015년 ~ 현 재 아주대학교 전자공학과
석사과정
관심분야 : Digital Signal Processing,
Machine Learning, Human
Activity Recognition



최 선 택

e-mail : suntaag62@gmail.com
2011년 아주대학교 전자공학과(학사)
2011년 ~ 현 재 아주대학교 전자공학과
석 · 박사통합과정
관심분야 : Smart IoT Device, Mobile
Context Aware Computing,
Human Activity
Sensing/Recognition



조 위 덕

e-mail : wedukecho@gmail.com
1977년 ~ 1981년 서강대학교(공학사)
1981년 ~ 1983년 한국과학기술원(공학석사)
1983년 ~ 1987년 한국과학기술원(공학박사)
1983년 ~ 1990년 금성전기㈜, 기술연구소
신호처리연구실장

1990년 ~ 1991년 KAITECH 수석연구원
1990년 ~ 2003년 전자부품연구원 수석연구원, 시스템연구본부장
1995년 ~ 1995년 UK TTP/Cambridge 연구원
1995년 ~ 1996년 USA TCSI/Berkeley 연구원
2003년 ~ 2013년 (재)유비쿼터스컴퓨팅사업단 사업단장
2010년 ~ 2014년 Sonybrook Univ. Electrical Engineering,
 겸임교수
2004년 ~ 현 재 아주대학교 전자공학과 교수,
 라이프케어사이언스랩, 램디렉터
2006년 ~ 현 재 유비쿼터스컨버전스연구소, 연구소장
관심분야: Smart IoT Device, Well-ness System/Index,
 Lifelog big data, Healing Care Device/Service