

Eating Activity Detection and Meal Time Estimation Using Structure Features From 6-axis Inertial Sensor

Jun Ho Kim[†] · Sun-Tak Choi^{††} · Jeong Ho Ha[†] · We-Duke Cho^{†††}

ABSTRACT

In this study, we propose an algorithm to detect eating activity and estimation mealtime using 6-axis inertial sensor. The eating activity is classified into three types: food picking, food eating, and lowering. The feature points of the gyro signal are selected for each gesture, and the eating activity is detected when each feature point appears in the sequence. Morphology technique is used to post-process to detect meal time. The proposed algorithm achieves the accuracy of 94.3% and accuracy of 84.1%.

Keywords : Meal time, Eating Activity, Structural Feature, Activity Recognition

6축 관성 센서에서 구조적 특징을 이용한 식사 행동 검출 및 식사 시간 추론

김 준 호[†] · 최 선 탁^{††} · 하 정 호[†] · 조 위 덕^{†††}

요 약

본 연구에서는 6축 센서를 이용하여 식사 행동을 검출하고 식사 시간을 추론하는 알고리즘을 제안한다. 식사 행동을 음식을 집는 동작, 음식을 먹는 동작, 팔을 내려놓는 동작으로 분류하고, 각 동작 별로 차이로 신호의 특징점을 선정하고 특징점이 순서대로 나타날 경우 식사 행동을 검출한다. 제안한 알고리즘은 정확도 94.3%와 정밀도 84.1%를 달성하였다.

키워드 : 식사 시간, 식사 행동, 구조적 특징, 행동 인식

1. 서 론

자동화된 웨어러블 디바이스를 이용한 Quantified Self[1] 서비스에서 운동, 수면, 식사 활동은 주요 관리 목표이다[2]. 과거부터 웨어러블 디바이스를 이용한 운동과 수면 측정 및 분석에 대한 연구가 다양하게 진행됐다. 이는 신체에서 발생하는 움직임을 수치적으로 측정하여 움직임의 강도에 따라 운동과 일상 활동, 수면을 구분한다. 하지만 식사 행동은 일상 활동과 그 움직임의 강도가 유사하여 더 정밀한 동작을 파악하여 측정해야 한다.

* 본 연구는 2017년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [C05661760100476491].

† 준 회 원 : 아주대학교 전자공학과 공학석사

†† 준 회 원 : 아주대학교 전자공학과 석·박사통합과정

††† 종신회원 : 아주대학교 전자공학과 교수

Manuscript Received : November 23, 2017

First Revision : April 23, 2018

Accepted : July 13, 2018

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

초기에 제안된 방법은 영상 신호를 이용하거나 다중 홈 센서 기반 측정 방식인데, 이러한 방법은 영상 기기나 센서를 특정한 장소에 정확히 설치해야 하므로 장소의 제약이 생긴다[3-6]. 이러한 문제를 해결하기 위해 최근에는 손목 착용형 디바이스를 이용하는 방법이 제안되고 있다.

손목 착용형 디바이스를 이용한 연구는 주로 기계 학습 기법을 활용하였다[7-10]. 이와 같은 이전 연구들에서는 식사 행동을 검출하기 위한 모델 학습 목적으로 통계적 특징들을 주로 사용한다. 이는 학습 모델에 의존적인 형태로, 움직임에 의한 관성 신호를 분할하여 광범위한 산술적 통계치를 산출한다. 이후, 학습 모델의 원리에 따라 특정 특징의 가중치를 고려하여 행동을 분류하게 된다. 그러나 이러한 방법은 실험으로 수집된 데이터에 의존적인 과적합 문제(Over-fitting Problem)를 야기할 수 있으며 선정된 특징이 설명하는 바를 이해할 수 없다. 즉, 학습된 분류 모델을 확장하거나 개선하기 위해서는 기존 수집 데이터를 추가하고 다시 반복 학습시

킬 수밖에 없다. 따라서 테이터의 양에 의존적이지 않으며 확장성을 갖기 위해서는 동작에서 발생하는 세밀한 관성 신호의 특징을 정량적으로 분석하고 이해할 방법이 필요하다.

Bao 외 2명은 다양한 위치에 작용한 관성 센서 모듈을 이용하여 시간 영역에서 평균, 에너지, 상관 분석값, 주파수 영역에서의 엔트로피 특징을 산출한 후 Decision Tree(DT), Instance Based Learning, Naive Bayes와 같은 기계 학습 알고리즘을 이용한 행동인식 기법을 제안하였다[7]. S Zhang 외 3명은 식사 시 팔 동작에 의한 관성 신호를 구조적으로 모델링한 후 팔의 각도를 측정하여 3차원의 각도 별 평균과 표준편차 특징값을 Hierarchical Temporal Memory 기법에 적용하여 식사 행동을 검출하였다[8]. Oliver Amft 외 2명은 위쪽 팔(상완)과 아래쪽 팔(전완)에 각각 단일 센서를 부착한 후 칼만 필터를 이용하여 상완과 전완의 각도를 산출하여 은닉 마르코프 모델(Hidden Markov Model)을 이용하여 식사 행동을 인지하였다[9]. 기타 접근 방법으로는 Yujie Dong 외 4명이 제안한 방법과 같이 관성 센서로 식사 전에 식사 준비 행동을 함께 고려한 방법이 있다[10]. Table 1은 기존 기계 학습 기반의 접근 방법을 보여준다.

앞서 언급한 문제들을 해결하기 위해 박경찬 외 2명은 과형 분석법 기반의 식사 행동 인식 기법을 제안한 바 있다 [11]. 해당 연구는 3축 가속도 신호에서 오일러 각도를 산출하여 식사 시 음식물을 그릇에서 입까지 손목이 왕복하는 동작을 검출하였다. 이러한 동작의 설명에 특화된 방법들은 기존 기계 학습 기반의 행동 인식 알고리즘보다 단발성 행동을 검출하는 데 효과적이었다. 하지만 이전 연구에서 식사 동작 인식에 대한 몇 가지 한계점을 발견했다.

첫 번째로, 행동 자체가 비슷하여 유사한 신호가 측정되는 문제가 있었다. 비슷한 행동으로는 안경을 고쳐 쓰거나 머리를 만지는 동작 등이 있었다. 이러한 문제를 해결하기 위해, 본 연구에서는 식사 동작과 수반되어 높은 빈도로 나타나는 특정 행동을 선정하고, 이를 식사 행동 검출에 결합하여 활용하고자 한다. 해당 행동은 식기를 사용하여 그릇에 담겨있는 음식을 집는 행동으로, 입으로 가져가는 행동과 다른 축의 방향으로 회전하는 동작이다.

두 번째로, 행동은 다르지만 변환된 오일러 각도 신호가 유사한 경우가 있었다. 가속도 센서는 질량을 고려하지 않을 때 센서에 작용하는 힘에 대응되는 가속도 값을 측정한다. 즉, 운동에 의한 힘 외에 중력, 원심력, 충격력 등이 합쳐진 값으로 측정된다. 그러므로 이 중 가장 큰 힘인 중력에 기반을 두고 산출되는 오일러 각도는 다양한 오차 요소를 포함할 수밖에 없다. 본 연구에서는 식사 동작 시 발생하는 관성 신호에서 회전 성분을 더욱 정확히 측정하기 위하여 각속도 센서(자이로 센서)를 활용하고자 한다.

본 연구에서는 식사 시 음식을 입에 가져가는 행동과 음식을 집는 행동을 각속도 센서로 측정한 과형의 구조적 특징점을 선정하고 각 특징점을 간의 상대적인 위치와 상태 기계를 이용한 식사 행동 인식 기법을 제안 한다. 본 논문은 2장에서 식사 행동을 세분된 동작에 관해 서술하고, 3장에서는 식사 동작에 대한 관성 신호에 관해 설명한다. 4장에서는 본 연구에서 제안하는 식사 행동 인식 방법에 대해 보여준다. 5장에서는 제안하는 알고리즘과 기계 학습, 이전 알고리즘의 실험 결과, 최종적으로 6장에서 실험 결과 및 제안한 방법에 대해 논한다.

2. 식사 행동 분석

식사 행동은 넓은 범위로 보았을 때 식사를 하기 위한 모든 행동을 말한다. 그중 식사에서 가장 중요한 행동은 음식을 집고 팔을 움직여서 음식을 입으로 넣는 행동이다. 이 행동을 검출하기 위한 식사 행동으로 정의한다.

식사 행동을 자세히 분석하기 위해 식사 행동을 여러 가지 동작으로 나눈다. Fig. 1과 같이 식사 행동은 음식을 집는 동작, 음식을 입에 가져가는 동작, 팔을 내려놓는 동작 총 3가지로 나눌 수 있다.

2.1 음식을 집는 동작

식기를 집고 처음 음식을 먹을 때 나타나는 동작은 음식을 집는 동작이다. 음식을 집는 동작에서 팔의 움직임은 음식의 위치에 따라 달라진다. 가까이 있는 음식을 집을 때는 상완은

Table 1. Previous Work

Previous Work	Sensor	Method	Description
[7]	multi sensors 3-axis accelerometer	Decision Tree Instance Based Learning Naive Bayes	Detecting many activities
[8]	one sensor 3-axis accelerometer	Hierarchical Temporal Memory	Modeling arm angle
[9]	2 sensors inertial sensor	Hidden Markov Model	Use two sensor Calculate angle between arms
[10]	6-axis inertial sensor	Naive Bayes	Using feature from before eating



Fig. 1, 3 Gestures in Eating Activity

거의 움직이지 않은 채 전완만 움직여서 음식을 집게 된다. 멀리 있는 음식을 집을 때는 팔을 뻗어야 하므로 상완과 전완을 전부 움직여서 음식을 집게 된다. 그러나 두 가지 경우 모두 음식을 집을 때 식기에서 음식을 집는 부분이 아래쪽을 향하게 되는 공통점이 있다.

2.2 음식을 입에 가져가는 동작

음식을 집은 후에는 음식을 입에 가져가는 동작이 나타난다. 음식을 들어 올릴 때 전완을 들어 올리면서 음식을 입으로 옮기게 된다. 그와 동시에 음식이 식기의 아래 부분에 있기 때문에 음식을 입으로 가져가기 위해 손목이 회전하게 된다. 또한, 음식에 따라 고개가 같이 움직이게 되고, 이럴 경우에는 전완의 움직임이 작아질 수 있다.

2.3 팔을 내려놓는 동작

음식을 입으로 가져가는 동작 다음에는 팔을 내려놓는 동작이 나타난다. 입으로 옮기면서 들어 올린 전완이 내려오면서 입 쪽으로 회전한 손목이 반대 방향으로 회전하게 된다. 팔을 내려놓는 동작은 바로 음식을 집을 경우에 음식을 집는 동작에 포함될 수 있는 동작이다. 식사 행동은 팔을 내려놓으면서 1회가 끝나게 된다. 식사 행동은 식사 시 최소 10회에서 30회 이상도 나타나며 이는 음식이나 개인별 식사량에 따라 차이가 나타난다.

3. 식사 행동 신호 분석 및 매개변수화

식사 행동 신호를 분석하기 위해 식사 실험을 통하여 식사 행동 신호를 수집하였다. 식사 행동 실험은 Fig. 2와 같이 피실험자의 팔목에 디바이스를 착용하여 진행하였다. 사용한 디바이스는 자체 제작한 디바이스를 이용하였다. 자체 제작한 디바이스는 STM LSM6DS3 6축 센서를 탑재하였다. 실험은 20대 남성 오른손잡이 4명을 대상으로 진행하였다. 식사 시간 실험은 식사 시간 앞뒤로 1~2시간 이내로 1회씩 데이터를 수집하고 식사 시간을 라벨링 하였다.

아래 Fig. 3의 식사 데이터 중 가속도 신호 데이터에서는 식사 행동이 나타날 때마다 한 축을 제외한 나머지 2축이 교차하는 현상이 보인다. 이러한 현상은 손목이 회전하면서 중

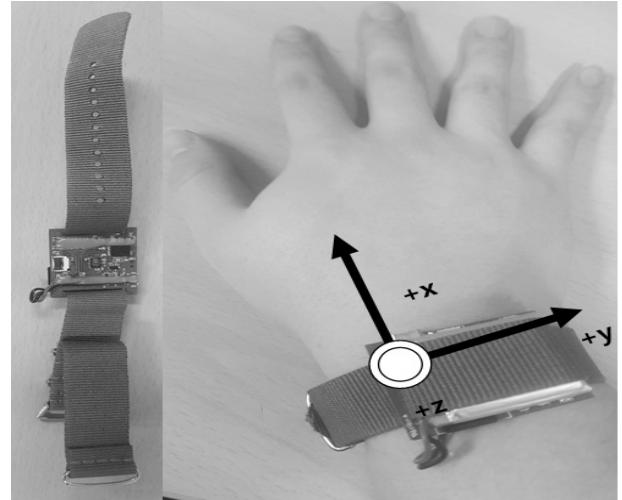


Fig. 2. The Orientation of the Sensor on the Wrist

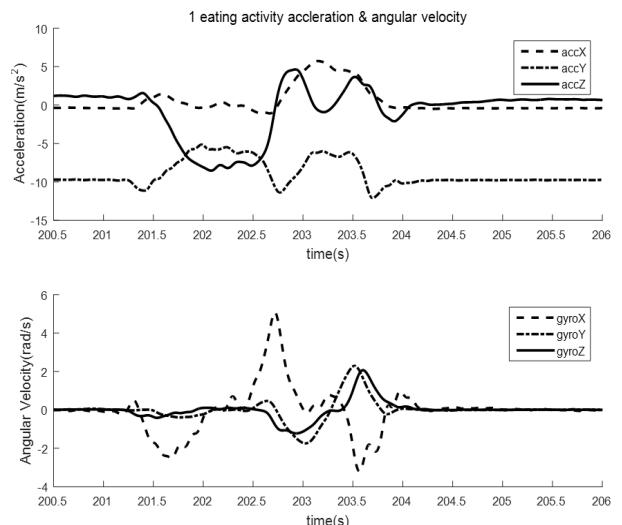


Fig. 3. Eating Activity Acceleration & Angular Velocity

력이 측정되는 센서의 방향이 바뀌기 때문에 나타나는 현상이다. 중력의 방향이 바뀌는 현상은 식사 행동 외의 다른 행동에서도 쉽게 나타나고 앞서 말한 가속도의 문제 때문에 가속도 신호에서 특징점을 설정하지 않았다.

Fig. 3의 식사 데이터 중 자이로 신호 데이터에서는 손목의 회전에 따라 첨미값과 첨두값이 나타난다. 처음에는 음식을 집기 위해 식기를 세우면서 $gyroX$ 의 신호가 아래로 움직인다. 그 후 음식을 입으로 가져갈 때 $gyroX$ 는 위로 $gyroZ$ 는 아래로 동시에 움직인다. 그 후 팔을 내려놓으면서 다시 $gyroX$ 는 아래로 $gyroZ$ 는 위로 움직인다. 각 동작 별 움직임에 따라 그림 3과 같은 신호가 나타난다. 그림 3에서 나타나는 첨두값과 첨미값을 식사 행동을 인지하기 위한 특징점으로 설정한다. $gyroY$ 는 식사 중에 손목이 $gyroY$ 방향으로 회전하는 경우가 없기 때문에 제외하였다.

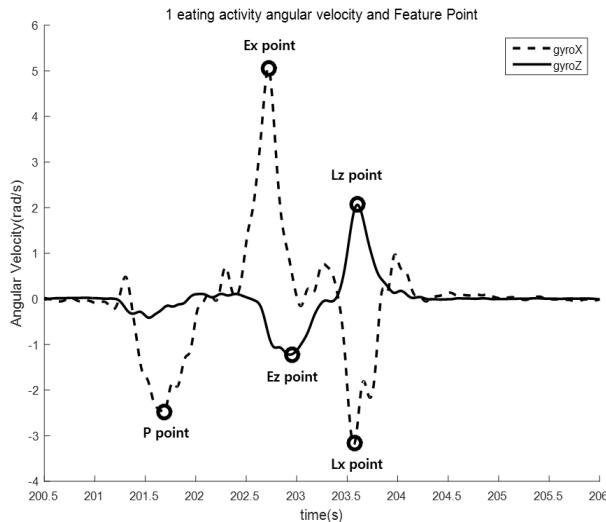


Fig. 4. Eating Activity Angular Velocity and Feature Point

식사 행동과 신호에 따라 차이로 신호에 특징점을 설정하면 Fig. 4와 같이 나타난다. 식사 행동에서 나타나는 3가지 동작인 음식을 집는 동작(Pick), 음식을 먹는 동작(Eat), 팔을 내려놓는 동작(Lower)에 따라 P, E, L 특징점을 선정하였다.

P(Pick) 특징점은 음식을 집을 때 나타나는 첨미값이다. 음식을 집기 위해 식기를 세우면서 손목이 $gyroX$ 축 - 방향으로 회전하게 된다. 차이로 센서는 각속도를 측정하므로 P 특징점은 회전하는 중 가장 속도가 빠른 지점이 되고 P지점 이후 $gyroX$ 값이 0 근처에 갔을 때가 음식을 집은 순간이 된다. 즉, P 특징점을 검출하면 음식을 집는 동작을 추론할 수 있다.

Ex, Ez(Eat) 특징점은 음식을 입으로 가져갈 때 나타나는 신호이다. 팔을 들어 올리면서 손목에 있는 센서의 위치가 바뀌는데 센서 중심을 기준으로 하면 차이로 Z축이 - 방향으로 회전하게 된다. 동시에 입 쪽으로 음식을 옮기면서 손목이 $gyroX$ 의 +방향으로 회전하게 된다. P 특징점과 같이 팔이 움직이면서 최고 속도인 부분에서 Ex, Ez 특징점이 발생하며 Ex와 Ez는 거의 동시에 발생한다.

Lx, Lz(Lower) 특징점은 음식을 먹고 팔을 내려놓을 때 나타나는 신호이다. 팔을 내리면서 Ex, Ez 특징점과 반대로 센서가 차이로 Z의 +방향으로 회전하게 되고, 입 쪽으로 돌린 손목도 다시 돌아가면서 손목이 $gyroX$ 의 - 방향으로 회전하게 된다. 또한 센서의 자체 회전으로 인해 $gyroX$ 의 - 방향으로 회전하는 힘이 더 가해진다. Lx와 Lz도 거의 동시에 발생한다. Lx가 Lz에 비해 크기가 크게 나타나는 데 x축은 손목을 트는 것이라 짧은 시간에 빠르게 움직이고 z축은 팔꿈치를 기준으로 크게 움직이기 때문에 느리게 움직이기 때문이다.

4. 식사 행동 인지 알고리즘

수집한 데이터는 잡음이 매우 많기 때문에 저역 통과 필터

를 이용하여 잡음을 제거하였다. 저역 통과 필터 차수는 15, 차단 주파수는 1Hz, Window는 Hamming Window로 설정하였다. 또한, 식사 신호는 움직임이 크지 않으므로 3축 가속도 신호에서 Equation (1)을 이용하여 운동량(momentem)을 산출한 후 움직임이 큰 행동을 제거하였다.

$$momentem = \sqrt{(accX)^2 + (accY)^2 + (accZ)^2} \quad (1)$$

(accX, accY, accZ : 3축 가속도의 X, Y, Z의 값)

그리고 운동량에서WindowSize가 1분이고 1초씩 이동하면서 이동 평균 필터를 이용하여 1분당 평균 에너지를 산출하였다. 이때 1분당 에너지가 일정 임계치 값 이상이면 그 1분 내의 움직임은 큰 행동으로 판단하고 식사 행동에서 제외한다. 본 연구에서는 임계치를 $9.9m/s^2$ 으로 설정하였다.

5가지 특징점 중에 크기가 가장 크게 나타나는 특징점은 Lx와 Lz이다. 즉, P 특징점이나 Ex, Ez 특징점보다 쉽게 구분할 수 있으므로 Lx, Lz 특징점을 먼저 찾는다. Lx와 Lz 중에는 크기가 더 큰 Lx를 찾는다. Lx는 첨미값이면서 값의 크기가 다른 특징점에 비해 크게 나타난다. 이를 이용하여 신호에서 첨미값을 찾고 이 중 크기가 0.5 rad/s 이상인 값을 찾는다. Lx의 후보 중에는 P 특징점이 존재하는 경우가 있다. 이때 P특징점과 Lx 특징점을 구별하기 위해 Lz를 찾는다. Lz는 Lx 위치를 기준으로 앞뒤 1초 안에 존재하게 된다. Lz는 첨두값이며 크기가 0.5 rad/s 이상인 특징점을 찾는다. Lz를 찾으면 Lx 후보에서 P 특징점은 제외되게 된다.

가장 확실히 나타나는 L 특징점을 찾으면 이제 E 특징점을 찾는다. L 특징점 기준으로 1.5초 이내에 존재하는 첨두값과 첨미값을 찾는다. 이때 1.5초는 평균적인 식사 행동 1회의 시간이 2~3초이므로 그 시간의 50~70%를 고려한 시간이다. Ex는 Lx와 반대로 첨두값이며 크기가 0.5 rad/s 이상이다. Ex를 찾은 후에는 Ez를 찾는다. Ez는 차이로 z에서 나타나는 신호로 첨미값이며 Ex와 같이 크기가 0.5 rad/s 이상이다.

L 특징점 E 특징점 전부를 찾고 난 후에는 마지막 특징점인 P 특징점을 찾는다. L 특징점과 E 특징점을 검출한 후 L 특징점 앞의 3초 이내 $gyroX$ 축의 첨미값을 찾는다. 크기가 1 rad/s 이상이며 P 특징점에서 앞뒤 1초 안에 $gyroZ$ 의 값에서 0.5 rad/s가 넘는 값이 없을 때 P 특징점으로 검출한다. 특징점을 선정할 때 조건을 만족하는 후보가 여러 개가 있으면 크기가 가장 큰 값을 특징점으로 선정한다.

이렇게 L 특징점, E 특징점, P 특징점을 전부 찾으면 특징점이 순서에 맞게 P, E, L 순으로 나타났는지 확인한다. 순서가 제대로 나타나지 않은 경우는 식사 행동으로 고려하지 않고 제대로 나타났을 때 식사 행동 1회로 검출한다.

식사 행동을 찾으면 식사 행동이 검출된 시간이 식사 시간 인지를 추론한다. 식사 행동은 안경을 만지거나 머리를 만지



Fig. 5. Labeled Eating time and Detection Eating Time

는 것과 같이 오인 될 수 있는 행동들이 많다. 이러한 문제를 해결하기 위해 P특징점을 검출함으로써 오인 행동을 많이 제거했지만 그런데도 오인 행동이 식사 행동으로 검출되는 경우가 많다.

이런 오인 행동을 제거하고 식사 시간을 추론하기 위해 영상처리기법에서 사용하는 모폴로지 기법을 이용한다. 일단 식사 행동은 불규칙적이지만 반복되므로 일정 시간 내에 일정 횟수만큼 나타나고 연속적으로 나타난다. 이러한 식사의 특징을 이용하여 모포로지 기법의 열림(Opening)과 닫힘(Closing)을 이용하여 식사 시간을 추론하고자 한다.

Fig. 5에서 첫 번째 그림은 분 단위로 실제 식사 시간을 표시한 그림이다. 두 번째 그림은 위의 특징점을 통하여 식사 행동을 검출한 시간을 분 단위로 표시한 그림이다. 두 번째 그림을 보면 제안한 알고리즘을 이용하여 첫 번째 그림에서 식사 시간으로 표시된 부분을 검출한 것을 확인할 수 있지만, 그 외에 다른 오인 행동 또한 식사 행동으로 검출된 것을 알 수 있다.

이러한 오인 행동들을 제거하기 위해 형태소를 5분으로 설정하여 열림을 적용한다. 이는 5분 이내의 식사 행동은 식사 행동으로 보지 않는 것이다. 식사 시간 외에 나타난 오인 행동은 반복적이지 않으므로 침식(Erosion)기법을 적용하면서

사라지고 식사 시간은 남게 되고 팽창(Dilation)기법을 적용하면 남은 식사 시간이 다시 원래대로 돌아온다. 그리고 식사 시간이 떨어져서 나타나는 것을 방지하기 위해 형태소를 10분으로 설정하여 열림과 순서가 반대인 닫힘을 적용한다. 즉, 10분 이내에 식사가 있으면 그 10분을 식사로 간주한다. 형태소의 시간은 개인별, 식사 음식별로 최적의 값이 다르다.

5. 결 과

식사 시간을 추정하는 것은 시간을 분 단위로 고려하여 식사 시작 시각부터 식사 종료 시각까지의 시간을 얼마나 정확하게 추정했는지 확인하는 것이다. 제안하는 알고리즘은 식사 행동이 나타난 시각을 확인하고 후처리를 하여 식사 시간을 추정하였다. 비교를 위해 구현한 알고리즘은 통계적 특징을 이용한 기계 학습 방법과 [11]의 오일러 각을 산출하는 방법이다. 통계적 특징을 이용한 방법은 특정으로 1분단위로 각 축마다 평균, 중간값, 표준편차, 사분위, 최댓값, 최솟값을 사용하였다. 기계 학습 방법은 Decision Tree(DT), K Nearest Neighbor(KNN), Support Vector Machine(SVM)을 이용하였다. [11]은 오일러 각으로 변환하여 저역 통과 필터와 양자화를 이용하여 전처리하였다. 그 후 임계치에 맞는 첨두값과 첨미값을 찾아서 손목 왕복 운동을 한 후 후처리를 통해 식사 시간을 검출하였다.

결과는 confusion matrix를 이용하여 표현하였고 True Positive(TP), False Positive(FP), False Negative(FN), True Negative(TN), 정확도(Acc.:Accuracy), 정밀도(Pre.:Precision), F1 score를 나타내었다. 그리고 각각의 평균(Avg.:Average)을 산출하였다.

Table 2~6의 결과는 식사 시간을 분 단위로 추정했을 때 결과이다. 수집한 데이터는 실험 1회당 120분 정도이며 이 중 식사 시간은 10~20분 정도이다. 전체 데이터에서 식사 시간 데이터가 적기 때문에 전부 식사가 아니라고 했을 때 최소 인식률이 상당히 높게 나타난다. 즉, 알고리즘을 정확도로 판단할 수 없기 때문에 F1 score를 이용한다. F1 score는 재현율과 정밀도의 조화평균이다.

Table 2. Meal Time Detection using DT

	Decision Tree						
	TP	FP	FN	TN	Acc	Pre	F1 score
1	10	0	14	66	0.844	1.000	0.588
2	7	13	17	88	0.760	0.350	0.318
3	0	9	5	115	0.891	0.000	0.000
4	16	3	4	80	0.932	0.842	0.821
5	15	4	38	123	0.767	0.789	0.417
6	1	13	17	179	0.857	0.071	0.063
Avg.	-	-	-	-	0.842	0.509	0.368

Table 3. Meal Time Detection using KNN

	K Nearest Neighbor						
	TP	FP	FN	TN	Acc	Pre	F1 score
1	10	0	6	74	0.933	1.000	0.769
2	16	4	20	85	0.808	0.800	0.571
3	6	3	18	102	0.837	0.667	0.364
4	16	3	7	77	0.903	0.842	0.762
5	15	4	39	122	0.761	0.789	0.411
6	4	10	1	195	0.948	0.286	0.421
Avg.	-	-	-	-	0.865	0.731	0.550

Table 4. Meal Time Detection using SVM

	Support Vector Machine						
	TP	FP	FN	TN	Acc	Pre	F1 score
1	10	0	8	72	0.911	1.000	0.714
2	14	6	19	86	0.800	0.700	0.528
3	0	9	20	100	0.775	0.000	0.000
4	15	4	7	77	0.893	0.789	0.732
5	14	5	33	128	0.789	0.737	0.424
6	5	9	2	194	0.948	0.357	0.476
Avg.	-	-	-	-	0.853	0.597	0.479

Table 5. Meal Time Detection using [11] Algorithm

	[11] Algorithm						
	TP	FP	FN	TN	Acc	Pre	F1 score
1	11	91	0	47	0.389	0.108	0.195
2	4	59	16	39	0.364	0.063	0.096
3	6	120	17	64	0.338	0.048	0.081
4	2	2	10	87	0.881	0.500	0.250
5	24	25	0	95	0.826	0.490	0.658
6	15	117	0	109	0.515	0.114	0.204
Avg.	-	-	-	-	0.552	0.220	0.247

Table 6. Meal Time Detection using Proposed Algorithm

	Proposed Algorithm						
	TP	FP	FN	TN	Acc	Pre	F1 score
1	12	4	0	85	0.960	0.750	0.857
2	19	4	5	112	0.936	0.826	0.809
3	11	2	0	136	0.987	0.846	0.917
4	6	0	14	98	0.881	1.000	0.462
5	9	0	14	184	0.932	1.000	0.563
6	15	9	0	217	0.963	0.625	0.769
Avg.	-	-	-	-	0.943	0.841	0.729

Table 2~4를 보면 기계학습을 이용한 식사 행동 인지 정확도는 대략 85% 정도로 최소인식률에 가깝게 나타났다. 그러나 Precision 값과 F1 score 값은 낮게 나타났다. Table 5를 보면 [11]의 알고리즘은 식사 행동이 아닌 오인 행동들을 식사 행동으로 인식하는 값(FP)이 크게 나타나서 정확도, 정밀도, F1 score가 전부 낮게 나타났다. [11] 알고리즘에서는 팔이 위아래로 움직이는 것을 식사 행동으로 검출하기 때문

에 오인 행동이 많이 나타났다.

제안하는 알고리즘은 기존 알고리즘들보다 정확도 면에서 큰 개선이 되지 않았지만, 음식을 집는 행동을 추가함으로 인해 오인 행동을 제거하여 정밀도 값이 개선되었다. Fig. 6은 다른 알고리즘과 제안하는 알고리즘의 정밀도 값을 표현한 그래프이다. 정밀도 값이 개선되면서 F1 score도 같이 개선되었다.

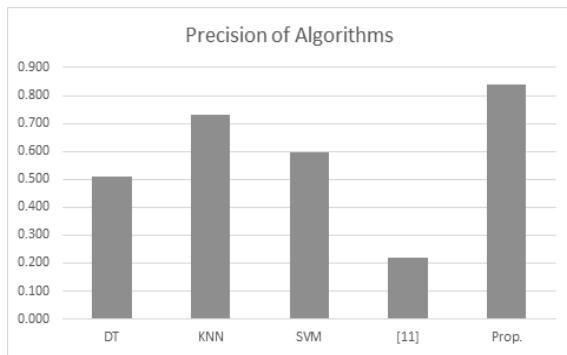


Fig. 6. Precision of Algorithms

6. 결 론

본 논문에서 손목에 착용한 임베디드 디바이스에서 6축 센서를 이용한 식사 행동 인지 알고리즘을 제안했다. 이 알고리즘은 식사 행동 시 나타나는 손목의 회전과 센서의 회전을 분석하여 식사 행동을 검출하고 움직임의 세기를 고려하여 오인 행동을 제거하였다. 그 후 모풀로지 기법을 이용한 후처리를 적용하여 식사 시간을 검출하였다. 식사 행동을 검출할 때 식사를 짍는 사전 행동을 추가하여 오인 행동을 제거하도록 하였다. 그래서 제안하는 알고리즘은 통계적 특징을 이용한 방법이나 오일러 각을 이용한 방법보다 정밀도와 F1 score가 높게 나타났다.

식사 행동 시 나타나는 손목의 회전과 센서의 회전을 고려한 알고리즘이지만 문제점이 존재한다. 첫 번째로 손목의 움직임만을 관찰하다 보니 손목의 움직임이 작은 경우에는 식사 행동이 관찰되지 않는 문제점이 있다. 예를 들어, 고개를 숙일 경우에는 팔을 들어 올리는 정도가 작으므로 $gyroZ$ 값이 작게 나타난다. 하지만 $gyroZ$ 를 고려하지 않으면 오인 행동이 많이 생기므로 Lz 임계치에 따라 인식률의 차이가 어느 정도 나타난다.

추후 식사 행동 특징점을 기계학습 기법이나 인공지능 기법에 적용할 수 있을 것 같다. 개인별 특징점을 학습시킨 후에 식사 신호 패턴 맹킹을 만들고, 이를 이용하면 좀 더 높은 식사 행동 인식률을 얻을 수 있을 것이다. 또한, 식사 전체를 보아 식기 이용 패턴을 검출하고, 어떤 종류의 음식을 먹는지 추론할 수 있을 것이다.

References

- [1] J. S. Park, J. M. Lim, and H. T. Jeong, "State-of-the-Art on Quantified Self Technology Based on Wearable Sensing," *Electronics and Telecommunications Trends*, Vol.30, No.4, pp.1–11, 2015.
- [2] S. S. Shin, "Trends and prospects of ICT convergence technology in wellness," *Weekly Technology on Trends Institute for Information and communications Technology Promotion*, pp.11–22, 2016.
- [3] A. Iosifidis, M. Ermioni, A. Tefaset, and I. Pitas, "Eating and drinking activity recognition based on discriminant analysis of fuzzy distances and activity volumes," in *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on IEEE*, pp.2201–2204, 2012.
- [4] A. Tolstikov, J. Biswas, C. K. Tham, and P. Yap, "Eating activity primitives detection—a step towards adl recognition," in *e-health Networking, Applications and Services, 2008. HealthCom 2008. 10th International Conference on IEEE*, pp.35–41, 2008.
- [5] E. M. Tapia, S. S. Intille, and K. Larson, "Activity recognition in the home using simple and ubiquitous sensors," *Pervasive*, Vol.4, pp.158–175, 2004.
- [6] H. M. Hondori, M. Kahademi, and C. V. Lopes, "Monitoring intake gestures using sensor fusion (microsoft kinect and inertial sensors) for smart home tele-rehab setting," in *2012 1st Annual IEEE Healthcare Innovation Conference*, 2012.
- [7] L. Bao and S. Intille, "Activity recognition from user-annotated acceleration data," *Pervasive Computing*, Vol.1, pp.1–17, 2004.
- [8] S. Zhang, M. H. Ang, W. Xiao, and C. K. Tham, "Detection of activities by wireless sensors for daily life surveillance: eating and drinking," *Sensors*, Vol.9, Issue.3, pp.1499–1517, 2009.
- [9] O. Amft, H. Junker, and G. Troster, "Detection of eating and drinking arm gestures using inertial body-worn sensors," in *Proceedings. Ninth IEEE International Symposium on Wearable Computers*, pp.160–163, 2005.
- [10] Y. Dong, J. Scisco, M. Wilson, E. Multh, and A. Hoover, "Detecting periods of eating during free-living by tracking wrist motion," *IEEE Journal of Biomedical and Health Informatics*, Vol.18, No.6, pp.1253–1260, 2014.
- [11] K. C. Park, S. T. Choe, and W. D. Cho, "A study on meal time estimation and eating behavior recognition considering movement using wrist-worn accelerometer with its frequency," *KIPS Transaction on Software and Data Engineering*, Vol.6, No.1, pp.29–36, 2017.



김 준 호

<https://orcid.org/0000-0002-2169-8116>

e-mail : junhokim218@gmail.com

2016년 아주대학교 전자공학과(공학사)

2018년 아주대학교 전자공학과(공학석사)

관심분야: Pattern Recognition,

Deep Learning



최 선 탁

<https://orcid.org/0000-0003-2648-1757>

e-mail : suntaag62@gmail.com

2011년 아주대학교 전자공학과(공학사)

2011년~현 재 아주대학교 전자공학과
석 · 박사통합과정

관심분야: Smart IoT Device, Mobile Context Aware Computing, Human Activity Sensing / Recognition



조 위 덕

<https://orcid.org/0000-0002-2895-0791>

e-mail : wedukecho@gmail.com

1977년~1981년 서강대학교(공학사)

1981년~1983년

한국과학기술원(공학석사)

1983년~1987년

한국과학기술원(공학박사)

1983년~1990년 금성전기(주), 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

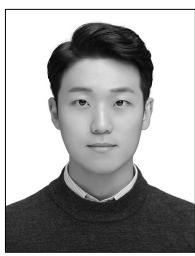
겸임교수

2004년~현 재 아주대학교 전자공학과 교수,

라이프케어사이언스랩, 랩디렉터

관심분야: Smart IoT Device, Well-ness System/Index,

Lifelog bio data, Healing Care Device/Service



하 정 호

<https://orcid.org/0000-0002-6757-8101>

e-mail : hjh5470569@gmail.com

2016년 아주대학교 전자공학과(공학사)

2018년 아주대학교 전자공학과(공학석사)

관심분야: Machine Learning, Artificial Intelligence, Fuzzy, Vehicle Component, Infotainment System