

# 시간 간격 특징 벡터를 이용한 AdaBoost 기반 제스처 인식

## AdaBoost-Based Gesture Recognition Using Time Interval Trajectory Features

황승준\*, 안광표\*, 박승제\*, 백중환\*

Seung-Jun Hwang\*, Gwang-Pyo Ahn\*, Seung-Je Park\* and Joong-Hwan Baek\*

### 요 약

본 논문에서는 키넥트 센서를 이용한 AdaBoost 기반 제스처 인식에 관한 알고리즘을 제안한다. 최근 스마트 TV에 대한 보급으로 관련 산업이 주목받고 있다. 기존 리모컨을 이용하여 TV를 컨트롤 하던 시대에서 벗어나 제스처를 이용하여 TV를 컨트롤 할 수 있는 새로운 접근을 제안한다. AdaBoost 학습 모델에 신체 정규화 된 시간 간격 특징 벡터의 집합을 특징 패턴으로 하여, 속도가 다른 동작들을 인식할 수 있도록 하였다. 또한 속도가 다른 다양한 제스처를 인식하기 위해 다중 AdaBoost 알고리즘을 적용하였다. 제안된 알고리즘을 실제 동영상 플레이어와 연결하여 적용하였고, 실험 후 좌표 변화를 이용한 알고리즘에 비해 정확도가 향상되었음을 확인하였다.

### Abstract

The task of 3D gesture recognition for controlling equipments is highly challenging due to the propagation of 3D smart TV recently. In this paper, the AdaBoost algorithm is applied to 3D gesture recognition by using Kinect sensor. By tracking time interval trajectory of hand, wrist and arm by Kinect, AdaBoost algorithm is used to train and classify 3D gesture. Experimental results demonstrate that the proposed method can successfully extract trained gestures from continuous hand, wrist and arm motion in real time.

Key words : 3D Gesture Recognition, Pattern Recognition, Machine Learning, Kinect, AdaBoost Algorithm.

### I. 서 론

사회 흐름이 계속해서 스마트화에 초점이 맞춰짐에 따라 전자기기 또한 스마트화 되어 이른바 스마트 TV, 스마트 냉장고, 스마트폰 등 여러 제품들이 개발 되고 있다. 이러한 기기들에서 볼 수 있는 공통적인 특징으로 컨트롤 방식에 변화를 꾀할 수 있다. 카메라와 센서의 기술이 발전함에 따라 과거에

는 생각할 수 없었던 여러 HCI(Human Computer Interaction)기술이 등장하고 있다. 이 논문은 여러 가지의 컨트롤 방식 중에서 카메라를 통하여 인간의 동작을 인식함으로써 기기를 제어하는 과정에 대한 알고리즘을 제안한다.

동작 인식에 관련된 연구는 시, 공간적 변이를 가진 패턴을 추출하는 은닉 마르코프 모델(Hidden Markov Model), DTW(Dynamic Time Warping) 등을 통하여 많은 부분 연구가 되었다 [1][2]. 본 논문에서

\* 한국항공대학교 정보통신공학부(Information & Telecommunication Engineering, Korea Aerospace University)

· 제1저자 (First Author) : 황승준(Seung-Jun Hwang, tel : +82-10-6730-5625, email : s-eungju-n@hanmail.net)

· 접수일자 : 2013년 4월 8일 · 심사(수정)일자 : 2013년 4월 8일 (수정일자 : 2013년 4월 18일) · 게재일자 : 2013년 4월 30일  
<http://dx.doi.org/10.12673/jkoni.2013.17.2.247>

서는 Kinect의 신체 좌표 정보를 이용하여 제스처를 인식하는 알고리즘을 제안한다. 3D 동작인식 하드웨어인 Kinect를 사용하므로 기존의 RGB영상 기반에서 배경모델을 구성하고 신체 정보를 가져오는 방식보다 신체 좌표 정보를 정확하게 가져올 수 있다. 이 신체 좌표의 일정시간 연속적인 누적 값을 제스처 및 학습모델의 시간 간격 특징 패턴으로 정의한다. 제스처는 사용자의 신장이나 사용자와 카메라의 거리에 따라 값의 크기가 변하는데, 이를 해결하기 위해 인식된 사용자의 어깨넓이로 신체의 크기를 나누면서 특징을 정규화 한다. 또한 제스처는 사용자의 움직임 속도에 따라 변하는데, 이 때문에 시간 및 공간적인 변이를 가진 패턴 추출법이 필요해진다. 이 논문에서 제안한 특징 벡터 샘플링 알고리즘은 시, 공간적인 변이를 가진 패턴 추출 알고리즘이 아닌 다른 학습 모델에서도 속도에 따른 제스처를 인식할 수 있도록 한다.

본 논문의 구성은 다음과 같다. 2장에서는 제스처 학습 및 인식을 위한 학습 모델에 대해 기술하고, 3장에서는 학습 모델의 특징이 되는 제스처 데이터의 취득 방법과 속도 변화에 따른 제스처 인식을 위한 특징 벡터의 정규화 및 샘플링 기법을 설명한다. 4장에서는 샘플링 된 특징 벡터의 학습 방법과 맵프레임 진행되는 제스처의 인식 방법을 기술한다. 5장에서는 제안한 알고리즘의 구현과 실험 결과를 보이며, 6장에서 결론을 맺는다.

## II. 학습 모델

### 2-1 시, 공간적 변이를 가진 패턴 추출법

제스처를 인식하기 위해서는 미리 지정된 동작인 참조 패턴과 사용자의 입력동작인 입력 패턴과의 패턴 매칭이 필요하다. 더불어, 사용자에 따라 변하는 제스처를 인식하기 위해서는 시간 및 공간적인 변이를 가진 패턴을 추출하는 기법이 필요하다. 시간 및 공간적인 변이를 가진 패턴을 추출하는 기법으로는 DTW, 신경망, 은닉 마르코프 모델 등을 들 수 있다.

DTW는 시간 축 상에서 비선형 신축을 허용하는 패턴 매칭 알고리즘이다. DTW 알고리즘은 입력 패턴과 참조 패턴의 거리 척도 값을 비용으로 설정하고 각 패턴의 시작에서 끝 성분까지 최소 비용을 택하는 동적 계획법으로 매핑 함수를 찾아가면서 두 열을 비교하기 때문에 여러 개의 후보를 낼 수 있다. 또한 역추적 방식을 이용하기에 입력 패턴과 참조 패턴의 시간 축이 일치 하지 않아도 적용이 가능하다.

신경망은 입력 패턴의 사후 확률을 계산하기에 다양한 후보를 낼 수 없다. 이러한 신경망은 훈련을 위해서 많은 양의 훈련 데이터를 필요로 한다. 제스처 인식과 같은 다양한 훈련 데이터를 만들기 어려운 분야에서는 적용하기 어려운 점이 있다.

은닉 마르코프 모델은 여러 개의 후보를 낼 수 있는 입력패턴과 참조패턴 사이의 유사도를 평가하는 방법을 사용하며, 시간 및 공간적인 변이가 각 상태와 전이에 확률적으로 표현되어 있어 매칭 과정에서 참조패턴의 시공간적인 변이에 대하여 추가적으로 고려할 필요가 없다 [1][3].

### 2-2 AdaBoost 알고리즘

AdaBoost 알고리즘은 분류 규칙을 순차적으로 생성하고, 이전의 분류 규칙을 적용하여 얻은 관측 값에서 샘플 데이터의 분포를 재조정한다. 학습 초기에 샘플 데이터의 가중치는 동일한 상태에서 시작하지만, 매 라운드가 진행될수록 이전의 분류 규칙을 적용하여 얻은 관측 값으로 오 분류 데이터에는 높은 가중치를 부여하고, 반대로 정 분류된 데이터에는 낮은 가중치를 부여하는 방식으로 샘플 데이터의 분포를 재조정한다. 이러한 과정은 분류하기 힘든 데이터에 우선권을 주기 위한 전략이다 [4].

AdaBoost 알고리즘은 특성상 동적인 특징 보다는 정적인 특징을 가진 자세 인식에 많이 사용한다 [5][6][7]. 이 논문에서는 AdaBoost 알고리즘과 같이 시, 공간적인 변이를 가진 패턴추출 방법이 아닌 기계학습 알고리즘에 동적인 특징을 인식하기 위한 정규화 된 특징 벡터를 이용한다. 이러한 특징 벡터를 제안하면서 기계학습 알고리즘에 제약 받지 않는 제스처 인식 방법을 제안한다. AdaBoost 알고리

즘은 아래의 식으로 정의 된다 [8].

1) 데이터를  $m$ 개 입력한다. 이는 학습할 데이터를 준비하는 과정이며  $m$ 은 학습 데이터,  $x_i$ 는 데이터 값  $y_i$ 는 데이터가 속한 클래스를 나타낸다.

$$(x_1, y_1), \dots, (x_m, y_m)$$

$$x_i \in X, y_i \in Y \in -1, +1$$

2) 초기분포  $D_1$ 를 구한다. 초기분포  $D_1$ 은 1을 입력 데이터의 개수로 나눈 값이다. 분포  $D$ 는  $T$ 회 반복 되면서 값이 업데이트 되는데 높은 값일수록 분류가 잘 안 되는 데이터이다.

$$D_1(i) = 1/m$$

3) 아래 과정을  $T$ 번 반복한다.(for  $t = 1, \dots, T$ )

① 오 분류율  $\epsilon_t$ 가 가장 작은 약한 분류기  $h_t$ 를 구한다. 약한 분류기는 입력  $x$ 에 대하여 클래스를 분류하는 간단한 형태의 분류기다.

$$\epsilon_t = \Pr_{i \sim D_t}[h_t(x_i) \neq y_i]$$

② 분포  $D$ 를 갱신하기 위하여  $\epsilon_t$ 로 가중치를 계산한다.

$$a_t = \frac{1}{2} \ln \left( \frac{1 - \epsilon_t}{\epsilon_t} \right)$$

③ 분포  $D_{t+1}$ 를 갱신한다. 잘 분류한 데이터에 대해서는 가중치를 낮추어 적용하고 잘못 분류된 데이터에 대해서는 가중치를 높여서 적용한다.

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-a_t} & h_t(x_i) = y_i \text{인 경우} \\ e^{a_t} & h_t(x_i) \neq y_i \text{인 경우} \end{cases}$$

4)  $T$ 번 반복하여 최종 분류자를 만든다. 여기서  $H(x)$ 는 강한 분류기이며,  $T$ 회 반복하는 동안 구한 가중치  $a_t$  값과 약한 분류기  $h_t$ 의 선형적인 결합으로 구한다.

$$H(x) = \text{sign} \left( \sum_{t=1}^T a_t h_t(x) \right)$$

### III. 제스처 취득

#### 3-1 KINECT 스켈레톤 데이터

사용자의 3D 데이터를 취득하는 기기로는 구조광을 이용한 Kinect, 시간 지연 방식의 TOF, 레이저를 이용한 Lidar 등 카메라 방식과 Wii 컨트롤러를 이용한 모션 데이터를 취득하는 방법들이 있다 [9]. 이 논문에서는 신체 좌표를 취득하는 것에 있어 Kinect를 사용한다. Kinect는 적외선 구조광을 이용하여 사용자의 신체를 스캔하고 신체를 총 20개의 관절로 구분하여 각각의 관절에서 3차원의 좌표 값을 취득한다. 본 연구에서는 Kinect를 사용함으로써 좌표 값 획득에 필요한 시간을 단축하였을 뿐만 아니라, 구동 환경에 있어서 조명에 따른 인식률의 변화를 적외선 센서를 통하여 최소화한다.

#### 3-2 특징 벡터

동작 인식을 사용하는 사람의 신체적 조건이 모두 동일할 수는 없다. 이러한 신체적 차이점에서 발생하는 문제점을 해결하기 위하여 특징 벡터를 제안한다. 신체의 비례를 이용한 특징 벡터를 사용함으로써 사용자의 신체 변화에 따른 인식률을 향상시킨다.

특징 벡터는 척추에서 손끝, 손목, 팔꿈치, 어깨까지의 네 개의 벡터로 정한다. 또한, 각각의 벡터를 사용자의 어깨 너비로 나눔으로써 정규화 한다. 이렇게 정규화 된 특징벡터는 사용자들의 신체 크기나 카메라와의 거리와 상관없는 유사한 값을 가지게 된다. 3차원 좌표상의 척추, 왼손끝, 왼손목, 왼팔꿈치, 왼어깨, 오른어깨를  $p_{spine}, p_{Lhand}, p_{Lwrist}, p_{Lelbow}, p_{Lshoulder}, p_{Rshoulder}$ 라 하면 특징 벡터  $F$ 는 다음 식 (1) 과 같다.  $f_1, f_2, f_3, f_4$  는 각 부위 별 어깨 너비에 의해 정규화된 특징 벡터이다.

$$f_1 = \frac{p_{spine} - p_{Lhand}}{p_{Rshoulder} - p_{Lshoulder}}, f_2 = \frac{p_{spine} - p_{Lwrist}}{p_{Rshoulder} - p_{Lshoulder}}$$


$$f_3 = \frac{p_{spine} - p_{Lelbow}}{p_{Rshoulder} - p_{Lshoulder}}, f_4 = \frac{p_{spine} - p_{Lshoulder}}{p_{Rshoulder} - p_{Lshoulder}}$$

$$F = [f_1, f_2, f_3, f_4] \quad (1)$$


학습 모델에 제스처를 특징 패턴으로 훈련하기 위해서 위의 특징 벡터  $F$ 의 연속적인 누적 값이 필요하다. 부분 정규화 된 특징 벡터  $f_1, f_2, f_3, f_4$ 는 3차원 좌표이기 때문에 특징 벡터  $F$ 는 12차원의 벡터가 된다. 이 논문에서는 식 (2)와 같이 특징 벡터  $F$ 의 60 프레임 동안의 연속적인 누적 값을 특징 패턴  $F_{pattern}$ 으로 정의한다.

$$F_{pattern} = [F_1, F_2 \dots, F_{59}, F_{60}] \quad (2)$$

이렇게 정의된 특징 패턴을 이용하여 한 손끝의 움직임 좌, 우 기본동작을 시행한 모습을 그림 1에 보인다. 좌에서 우, 우에서 좌의 제스처를 취한 모습이기 때문에  $x$  벡터의 변화가 서로 반대로 나타나는 것을 확인할 수 있다. 더불어,  $y$  벡터의 값은 변화가 생기지 않기에 0 값 부근에서 움직이는 것을 볼 수 있고, 팔의 움직임에 의해 생기는  $z$  벡터 값은 중간 프레임에서 신체 중심과 가장 멀리 있는 것을 확인할 수 있다.



(a) 좌에서 우 제스처 (Left to Right Gesture)



(b) 우에서 좌 제스처 (Right to Left Gesture)

그림 1. 좌-우 제스처 특징 패턴 그래프  
Fig 2. Graph of Left to Right Feature Pattern

### 3-3 특징 벡터 샘플링

시, 공간적인 변이를 갖지 않은 AdaBoost 학습 모델을 사용하기 때문에 위의 특징 패턴의 학습은 제스처의 속도 변화 인식에는 적당하지 않다. 속도가 다른 제스처를 인식하기 위해 다중 AdaBoost 분류기가 필요하며 그에 따른 특징 벡터 샘플링 과정이 필요하다. 본 연구에서는 60 프레임의 제스처를 특징 패턴으로 정한다. 이 특징 패턴은 인식할 수 있는 가장 느린 제스처이며, 샘플링을 통하여 20 프레임에 이루어지는 제스처까지 인식할 수 있게 한다.

특징 벡터 샘플링은 그림 2와 같이 60 프레임의 특징 패턴에서 특징 벡터 일부를 추출한다. 여섯 프레임 단위로 60 프레임의 기준 특징 패턴에서  $X$  표시된 특징 벡터를 삭제하면서 속도가 빠른 제스처의 특징 패턴을 생성한다. 아래와 같은 샘플링 방법으로 훈련 데이터의 취득 시간을 5배 축소할 수 있으며 속도가 다른 20 프레임에서 50 프레임의 제스처 특징 패턴을 생성한다.

	1	2	3	4	5	6
60 fame	○	○	○	○	○	○
50 fame	○	○	○	○	○	×
40 fame	○	○	×	○	○	×
30 fame	○	×	○	×	○	×
20 fame	○	×	×	○	×	×

그림 2. 특징 벡터 샘플링 방법

Fig 2. Sampling Method of Feature Vector

## IV. 제스처 학습 및 인식

속도가 다른 제스처를 인식하기 위해 다중 AdaBoost 분류기의 설계 및 설계된 분류기를 이용한 입력된 패턴의 제스처 인식 과정을 그림 3에 보인다. 위의 제스처 취득과 제스처 샘플링 과정을 통해 생성한 20 프레임에서 60 프레임의 특징 패턴을 이진 분류 방식을 이용하여 AdaBoost 분류기를 설계한다. 이 AdaBoost 분류기는 이진 분류 방식이기에 인식하고자 하는 제스처의 수만큼 다중 AdaBoost 분류기가 된다. 설계된 다중 AdaBoost 분

류기에 최근 20 프레임에서 60 프레임까지의 취득된 제스처 특징 패턴을 입력하면 각 제스처 분류기에 따라 참, 거짓의 결과를 내면서 제스처 인식이 가능하게 된다.

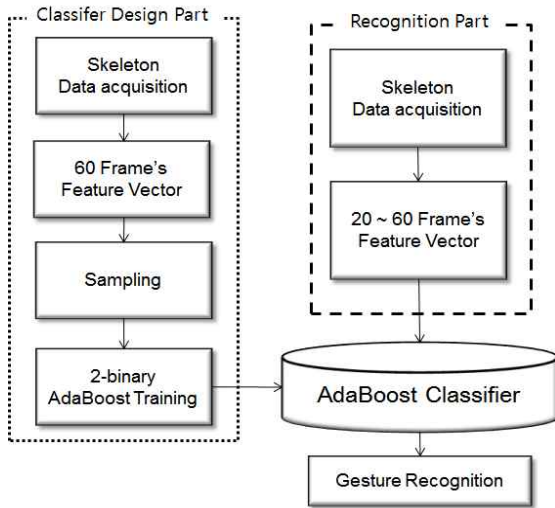


그림 3. 제스처 학습 및 인식 구조도  
Fig 3. Flowchart of Gesture Training and Recognition

4-1 샘플링 된 특징 벡터 학습

본 연구에서는 AdaBoost 알고리즘을 이용하여 입력 받은 동작이 참인지 거짓인지 판별하는 다중 AdaBoost 분류기를 사용한다. 분류 방식은 1:N의 이진 분류 방식을 사용하여 학습하고자 하는 동작을 제외하고 나머지 동작들을 모두 네거티브 역할을 하도록 한다. 따라서 동작을 제스처 1, 2, 3, 4로 구분하고 제스처 1 동작을 훈련하고자 할 때, 제스처 1을 제외하고 나머지 3개의 동작의 데이터는 전부 네거티브의 역할을 하도록 한다. 제스처 2, 3, 4 또한 마찬가지로 이진 분류 방식을 통해 학습되는 방법을 그림 4에 보인다. 동작을 위와 같은 이진 분류 방식으로 학습하면서 학습한 다른 동작으로 인식되는 오인식률을 줄일 수 있다.

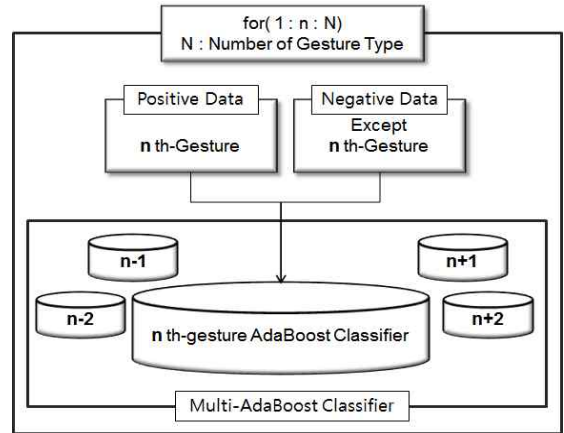


그림 4. 이진 분류 방식 및 다중 Adaboost 분류기  
Fig 4. Method of Binary Classification and Multi-Adaboost Classifier

4-2 제스처 인식

매 프레임에 진행되는 제스처 인식의 순서도를 그림 5에 보인다. 본 논문에서는 속도가 다른 제스처를 인식하기 위해 최근 20 프레임부터 60 프레임까지의 특징 벡터를 Adaboost 분류기에 입력한다. 분류기는 매 프레임 별 샘플링 된 수만큼의 제스처 인식을 수행한다.

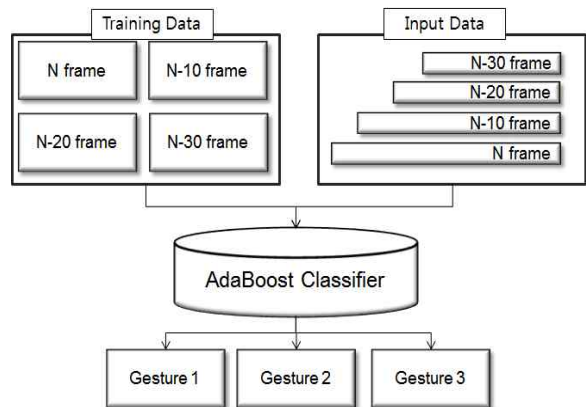


그림 5. 매 프레임 진행되는 제스처 인식 순서도  
Fig 5. Flowchart of Gesture Recognition per Frame

매 프레임 별 판별되는 제스처의 수는 제스처의 수와 샘플링 된 수에 비례한다.

V. 실험 및 결과

본 연구에서는 두 가지의 실험을 통하여 제안한 알고리즘의 성능을 확인한다. 첫 번째 실험에서 좌표의 변화로 동작을 인식하는 알고리즘과 제안한 알고리즘의 인식률을 다양한 실험자에 따라 비교하고, 두 번째 실험에서는 제안한 알고리즘에서 동작의 속도 변화에 따른 인식률 비교실험을 한다. 제스처 모델의 훈련 데이터의 수는 각 동작마다 세 명의 실험자로부터 얻은 총 450개이다. 신체 변화에 따른 실험 결과는 다섯 명의 실험자로부터 동작마다 20번의 평가를 통해, 동작 속도 변화에 따른 실험 결과는 세 명의 실험자로부터 동작마다 10번의 고, 중, 저속의 동작 평가를 통해 평균을 얻었다.

제안한 알고리즘의 성능 평가를 위하여 PC기반의 동영상 플레이어를 제어할 수 있는 시스템을 구축하였다. 그림 6은 실험실에서 제안한 알고리즘을 이용한 제스처 인식으로 동영상 플레이어를 제어하는 모습이다.



그림 6. 제스처 인식 시스템  
Fig 6. Gesture Recognition System

더불어, 테스트에 사용한 동작은 표 1과 같다. 다양한 제스처 동작 인식을 위해 한 손 동작뿐 아니라 양손의 복합적인 동작 인식도 좌, 우 제스처 인식의 결과 값을 이용해 가능하도록 하였다.

표 1. 제스처의 종류  
Table 1. Type of Gesture

제스처	명령어	비고
→ ←	다음 영상, 이전 영상	한 손동작
↑ ↓	소리 키움, 소리 줄임	한 손동작
↗ ↘	일시 정지	양 손동작
→ ←	재 생	양 손동작

제스처 인식과정에 제스처가 아닌 패턴을 제스처로 인식하는 경우가 발생한다. 좌, 우와 같은 동작을 한 후에 차렷 자세를 하는 것은 학습기에 훈련된 위에서 아래 동작과 유사하므로 오인식을 발생시킨다. 이러한 문제를 줄이기 위해 제스처가 아닌 사람의 자연스러운 동작이나 제스처 후 제자리 동작 등 총 1350개를 네가티브 데이터로 부가적으로 학습하였다.

5-1 신체 변화에 따른 비교 실험

좌표 변화 알고리즘의 경우 실험자 신체가 동작을 하는 도중 변화하는 좌표의 폭을 계산하여 절대값으로 만든 알고리즘이다. 이는 직관적이지만 테스트들의 체형에 따라 인식률이 떨어지게 된다. 이 실험에서는 체형이 다른 각각의 실험자에게 좌표 변화 알고리즘과 제안한 알고리즘을 적용하여 인식률의 변화를 알아본다.

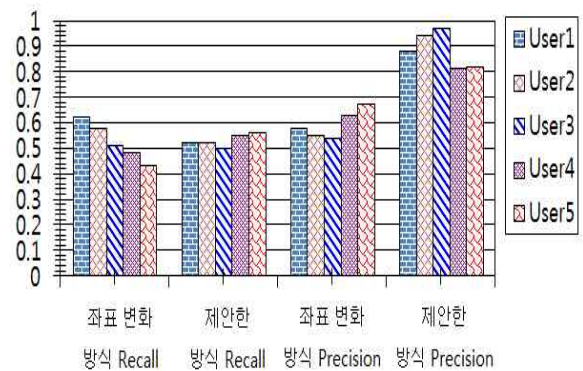


그림 7. 신체 변화에 따른 제스처 인식률  
Fig 7. Recognition Rate According to the Body Pose Changes

그림 7에서 나타나는 것과 같이 제안한 알고리즘의 Precision이 좌표 변화 알고리즘을 이용한

Precision 보다 높은 수치를 보이고 있다. 또한, 제안한 알고리즘에서 Recall 값은 높진 않지만 안정된 값을 보인다. 즉, 시간 간격 특징 벡터를 학습한 AdaBoost 알고리즘을 사용함으로써 사용자의 체형의 변화에도 인식률의 저하가 일어나지 않음으로 여러 사용자를 대상으로 사용될 수 있음을 알 수 있다.

5-2 동작 속도 변화에 따른 비교 실험

본 논문에서 제안하는 알고리즘의 가장 큰 특징은 샘플링을 이용하여 속도 변화에 강인한 것이다. 따라서 이번 실험은 속도의 변화가 있을 때 인식률의 변화에 대하여 알아본다.




그림 8. 동작 속도에 따른 제스처 인식률  
Fig 8. Recognition Rate According to the Motion Speed

그림 8에서 나타나는 것과 같이 속도의 변화에 따라 동작을 취하여도 인식률이 크게 변화되지 않는다. 또한, Precision의 값이 0.8에서 0.9까지로 높은 정확도를 보이고 있다. 즉, 제안하는 알고리즘은 사용자의 제스처 속도 변화에 강인하게 동작을 인식하는 것을 알 수 있다.

VI. 결 론

본 연구에서는 사용자의 동작 속도 변화에 영향이 적은 알고리즘을 제안하였다. 실험 결과에서도 알 수 있듯이 샘플링을 통하여 학습된 데이터베이스를 기반으로 분류를 함으로써 동작의 속도가 변

하여도 인식률의 저하가 일어나지 않음을 확인할 수 있었다. 또한 정규화 된 특징 벡터를 사용하여 사용자의 신체가 다르더라도 제스처의 인식률이 변화되지 않았다.

본 연구에서는 제안한 알고리즘을 이용하여 PC 기반의 미디어 플레이어를 제어함으로써 실험하였다. 향후 연구로는 현재 흐름에 맞추어 스마트TV에서 제스처 인식을 이용하여 편리하게 컨트롤할 수 있도록 할 것이다. 서두에서 말한 것과 같이 스마트 기기의 컨트롤 방식은 점점 더 편의를 추구하며 동작인식 위주로 발전할 것이다. 이러한 흐름 속에서 본 논문에서 제안하는 알고리즘이 속도 변화에 강건한 제스처 인식 알고리즘으로 기여하기를 기대한다.

감사의 글

본 연구는 경기도지역협력연구센터 (GRRRC) 프로그램에 의해 한국항공대학교 차세대방송미디어기술 연구센터의 지원으로 수행되었음.

Reference

[1] Lee, Hyeon-Kyu, and Jin-Hyung Kim. "An HMM-based threshold model approach for gesture recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp.961-973, 1999.

[2] Hong, Duan, and Luo Yang. "A Gestures Trajectory Recognition Method Based on DTW", *Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering*, 2013.

[3] Whitehead, Anthony, and Kaitlyn Fox. "Device agnostic 3D gesture recognition using hidden Markov models", *Proceedings of the 2009 Conference on Future Play on@ GDC Canada*, ACM, 2009.

[4] Freund, Yoav, Robert Schapire, and N. Abe. "A short introduction to boosting", *Journal-Japanese Society For Artificial Intelligence*, pp.771-780, 1999.

- [5] Wang, Chieh-Chih, and Ko-Chih Wang. "Hand Posture recognition using Adaboost with SIFT for human robot interaction", *Recent progress in robotics: viable robotic service to human*, pp.317-329, 2008.
- [6] Yao, Yi, and Chang-Tsun Li. "Hand Posture Recognition Using SURF with Adaptive Boosting", 2011.
- [7] Sheng, Jia. A study of adaboost in 3d gesture recognition. Technical report, University of Toronto, 2005.
- [8] Changrampadi, Mohamed Hashim. "A fusion-based multiclass AdaBoost for classifying object poses using visual and IR images", 2011.
- [9] Hoffman, Michael, Paul Varcholik, and Joseph J. LaViola. "Breaking the status quo: Improving 3d gesture recognition with spatially convenient input devices", *Virtual Reality Conference (VR), 2010 IEEE*, 2010.

### 박 승 제 (Seung-Je Park)



2008년 3월~현재 : 한국항공대학교  
정보통신공학과 재학 중  
관심분야 : 영상처리, 멀티미디어,  
패턴 인식

### 백 중 환 (Joong-Hwan Baek)



1981년 2월 : 한국항공대학교 항공  
통신공학과 졸업(공학사)  
1987년 7월 : 오클라호마주립 대학원  
전기 및 컴퓨터공학과 (공학석사)  
1991년 7월 : 오클라호마주립 대학원  
전기 및 컴퓨터공학과(공학박사)  
1992년 ~ 현재 : 한국항공대학교  
항공전자 및 정보통신 공학부 교수  
관심분야 : 영상처리, 패턴인식, 영상압축, 멀티미디어

### 황 승 준 (Seung-Jun Hwang)



2012년 2월 : 한국항공대학교 정보  
통신공학과(공학사)  
2012년 3월~현재 : 한국항공대학교  
정보통신공학과 석사과정  
관심분야 : 영상처리, 멀티미디어,  
3D Vision

### 안 광 표 (Gwang-Pyo Ahn)



2007년 3월~현재 : 한국항공대학교  
정보통신공학과 재학 중  
관심분야 : 영상처리, 멀티미디어,  
3D Vision