

# 동작센서를 통한 사용자 행동인식을 위한 HMM 기반 앙상블 방법

임성수<sup>○</sup> 조성배

연세대학교 컴퓨터과학과

[lss@sclab.yonsei.ac.kr](mailto:lss@sclab.yonsei.ac.kr), [sbcho@cs.yonsei.ac.kr](mailto:sbcho@cs.yonsei.ac.kr)

## HMM based Ensemble Method

### for Recognizing User Activities using Motion Sensors

Sungsoo Lim<sup>○</sup> Sung-Bae Cho

Dept. of Computer Science, Yonsei University

최근 센서 자원이 발전함에 따라서 카메라 마이크, 가속도 센서, 각속도 센서 등을 활용하여 사용자의 행동을 인식하고자 하는 연구들이 활발히 진행되고 있다 특히, 동작 센서의 경우 이미 엔터테인먼트 제품인 닌텐도 Wii를 통해서 성공적으로 적용되었고 최근 삼성의 햅틱, 옴니아 등의 모바일 기기에서도 동작 센서의 활용이 늘어나고 있다

본 논문에서는 동작 센서의 3축 가속도 값과 3축 각속도 값을 이용하여 수집된 사용자 행동 정보를 HMM 기반 앙상블 방법을 통해서 인식한다 HMM은 시간적으로 연속적이고 지속적인 공간 변화를 포함하고 있는 연속 데이터의 분류 문제에서 좋은 성능을 발휘한다 특히, 시작과 끝이 불분명한 동작 센서 데이터의 경우 실시간 분류가 가능한 HMM 모델의 사용이 유리하다 또한 HMM 모델은 수학적 배경과 효과적인 학습 알고리즘이 알려져 있고 가시적인 그래프 모델을 가지고 있기 때문에 활용의 이점이 크다, 본 논문에서는 모바일 환경의 새로운 인터페이스로서 동작센서의 활용에 중점을 두고 모바일 환경에서 나타날만한 행동을 20가지로 정의하고, 이 행동을 인식하기 위한 HMM을 학습시킨다. 그림 1은 제안하는 HMM 기반 앙상블 방법을 사용한 행동 인식기 구조를 보여준다

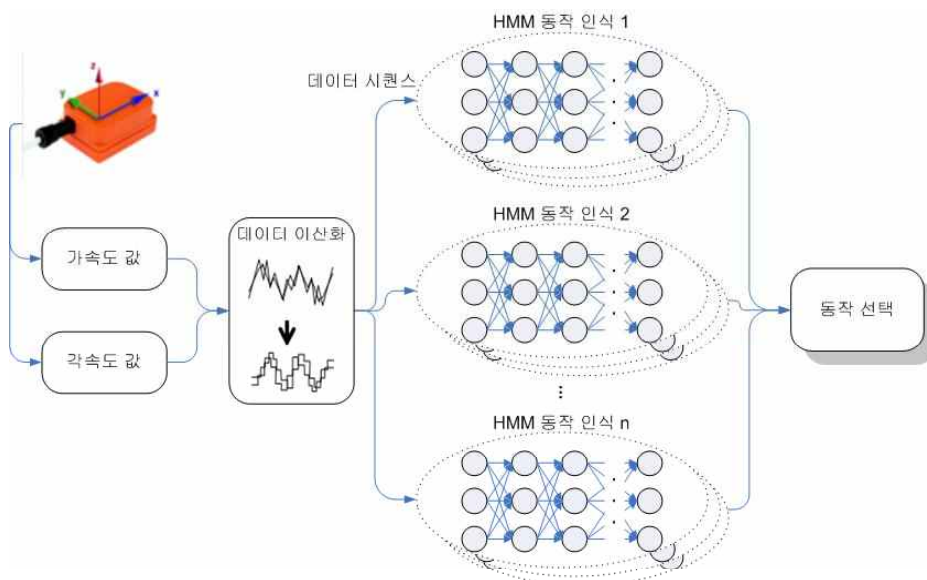


그림 1. 제안하는 행동 인식기 구조

HMM 모델을 설계하기 위해서는 우선 입력 심벌들을 정의할 필요가 있다. 본 논문에서 사용하는 입력은 가속도 값 및 각속도 값으로 연속적인 값이므로 이를 이산화(decartelization) 혹은 양자화(quantization)가 필요하다. 본 논문에서는 데이터 이산화 방법으로 데이터의 범위를 동일하게 하여 나누는 Uni-width, 데이터 분포를 동일하게 하여 나누는 Uni-count, 그리고 데이터들 간의 유클리디안 거리를 기반으로 계통수(dendrogram)이라 불리는 트리형식으로 구성하는 계층적 클러스터링의 세 가지 방법을 실험 평가하였다. HMM의 내부 상태의 개수를 6개, 이산화 개수를 6개로 하여 실험해본 결과, Uni-width, Uni-count, 계층적 클러스터링 방법의 정확률은 각각 63.8%, 11.8%, 92.6%로 계층적 클러스터링 방법이 사용자 행동 인식 데이터의 전처리로 적합함을 알 수 있다.

Geman 등은 MLP(Multi Layer Perceptron)를 현실문제에 적용함에 있어 발생하는 문제를 바이어스 분산(bias/variance) 딜레마라고 표현하였다[1]. 즉, 분산을 제어에 초점을 맞출 경우 추정된 모형의 바이어스가 커지고 반대로 바이어스의 제어에 초점을 맞출 경우 분산이 커지므로 양자간의 적절한 타협점을 찾는 것이 필요하다는 것이다. 동작 센서를 이용한 HMM 기반 사용자 행동 예측에 있어서도 바이어스/분산 딜레마의 문제가 발생한다. 즉, 학습데이터와 유사한 패턴의 입력을 인식하고자 하면 분산이 커져서 정확률이 떨어지고 반대로 분산을 줄이려고 하면 학습데이터 외의 패턴은 잘 인식하지 못한다. 따라서 본 논문에서는 Geman 등이 주장에 따라 HMM 모형의 내부 상태의 개수와 데이터 이산화 방법을 달리해보면 실험해본 결과, 약 45%의 성능만을 보여주었던 초기 모델에 비해 92%의 높은 성능을 갖는 HMM을 얻을 수 있었으나, 특정 행동 인식에 낮은 결과를 나타내었다. Schapire 등에 따르면 바이어스/분산 딜레마는 앙상블 머신의 분산은 단독 머신의 경우보다 줄어들게 되며 AdaBoost는 바이어스와 분산을 동시에 감소시키는 작용을 한다[2]. 따라서 본 논문에서는 동작센서로부터의 사용자 행동을 위해서 HMM의 상태와 심벌의 수를 변화시켜가며 다양한 HMM 분류기를 생성하고, 이들을 결합하는 HMM 기반 앙상블 방법을 적용하였다.

실험은 10-fold cross validation을 통한 교차검증을 수행하였으며, 모든 HMM에서 0의 확률값이 나온 경우를 제외한 데이터로 정확률을 측정하고, 0이 나온 경우의 데이터를 바탕으로 거부율을 계산한다. HMM 분류기를 결합하기에 앞서, 단일분류기의 성능을 확인해본 결과, 단일 HMM의 성능은 내부 상태보다는 이산화 개수에 더욱 민감한 것을 알 수 있었다(표 1, 2).

표 1. 이산화 개수에 따른 결과

개수	2	3	4	5	6	7	8	9	10
정확률 (%)	31.9	82.8	88.3	91.8	92.8	92.0	94.2	94.3	92.8
거부율 (%)	0	0	1.1	1.7	4.6	9.9	16.9	24.9	32.9

표 2. 은닉 상태 개수에 따른 결과

개수	2	3	4	5	6	7	8	9	10
정확률 (%)	90.8	91.8	92.1	92.0	92.8	92.9	92.3	93.2	93.2
거부율 (%)	4.6	4.6	4.7	4.6	4.6	4.6	4.6	4.6	4.6

본 논문에서는 거부율과 정확률을 고려하여 앙상블 분류기로 이산화 개수 3, 5, 7과 은닉 상태 개수 4, 6, 8, 10을 통해서 앙상블을 구성하기로 결정하였다. 이렇게 하여 실험해본 결과 거부율 0%에 정확률 96.7%의 성능을 얻을 수 있었다.

참고 문헌

[1] S. Geman, et. al. "Neural Networks and Bias/Variance Dilemma," *Neural Computation*, vol. 4, pp. 1-58, 1992.

[2] R.E. Schapire, et. al., "Boosting the Margin: A New Explanation for the Effectiveness of Voting Methods", *The Annals of Statistics*, vol. 26, no. 5, pp. 1651-1686, 1998.