

스마트폰 멀티모달 센서 기반 개인화 행위모델링 및 실시간 행위인지

(Personalized Activity Modeling and Real-time Activity
Recognition based on Smartphone Multimodal Sensors)

한 만 형 [†] 이 승 룡 ^{**}
(Manhyung Han) (Sungyoung Lee)

요약 스마트폰과 같은 모바일 기기의 발전으로 인해 다양한 센서를 통해 사용자의 의도나 요구사항을 인지하고자 하는 행위인지가 활발히 연구되고 있다. 기존의 행위인지 기술은 행위 데이터의 수집과 처리가 분리되어 있어 멀티모달 센서로부터 수집한 방대한 양의 데이터를 오프라인에서 모델링과 인지가 수행되므로 특정 사용자에게 개인화된 행위인지가 어렵고, 사용자가 직접 자신의 특정행위를 추가하거나 스스로 행위모델을 만들 수 있는 프레임워크의 부재로 개인화된 라이프로그의 수집이 어렵다는 한계가 있다. 본 논문에서는 스마트폰에서 개인화된 행위 모델링 및 실시간 행위인지를 위해, Naive Bayes 알고리즘을 확장한 적용형 Naive Bayes(A-NB) 알고리즘과 이를 기반으로 한 계층적 행위인지 프레임워크(HARF)를 제안한다. 이를 통해 스마트폰 환경에서 사용자가 스스로 자신의 행위를 모델링하거나 추가할 수 있으며, Naive Bayes에 비해 높은 정확도와 모바일 환경에서 실시간 행위인지가 가능하다. 제안 알고리즘의 평가를 위해 스마트폰 어플리케이션을 개발하여 15개의 행위를 실험하였으며 평균 92.96%의 높은 정확도를 보였다.

키워드: 행위인지, 스마트폰, 멀티모달센서, Naive Bayes, 라이프로그, 개인화

Abstract Activity recognition for the purposes of recognizing a user's intentions using multimodal sensors is becoming a widely researched topic largely based on the prevalence of the smartphone. Previous studies have reported the difficulty in recognizing personalized activities of individual users given that the collection and processing of the vast amount of activity data from multimodal sensors are separated and performed on off-line. In addition, recognizing personalized life-logs is difficult due to the absence of a framework which enables the addition of activities by the user themselves. In this paper, we propose an adaptive Naive Bayes (A-NB) algorithm and hierarchical activity recognition framework (HARF) which extends the Naive Bayes approach in an effort to personalizes the process of activity modeling & real-time activity recognition. Based on this approach, the users can add or model their own activities by themselves with a smartphone. The proposed algorithm demonstrates relatively higher accuracy than the Naive Bayes approach and also enables the recognition of the user's activities in a mobile environment. For the purposes of evaluation, we have developed a smartphone application. Based on this platform, the experimental results demonstrate that the proposed algorithm has the ability to classify fifteen activities with an average accuracy of 92.96%.

Keywords: activity recognition, smartphone, multimodal sensors, naive bayes, life-log, personalization

· 본 연구는 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NO. 2012-0009229)
· 본 연구는 지식경제부 및 정보통신산업진흥원의 IT/SW 창의연구과정의 연구 결과로 수행되었음(H0502-12-1012)

[†] 학생회원 : 경희대학교 컴퓨터공학
smiley@oslab.khu.ac.kr
^{**} 종신회원 : 경희대학교 컴퓨터공학 교수
sylee@oslab.khu.ac.kr
(Corresponding author)

논문접수 : 2012년 12월 21일
심사완료 : 2013년 3월 26일

Copyright©2013 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지 : 소프트웨어 및 응용 제40권 제6호(2013.6)

1. 서론

행위인지(Activity Recognition) 기술은 사용자의 물리적인 움직임, 동작, 이동정보 등을 다양한 센서를 통해 인지하는 기술로써 대상의 의도나 상태, 또는 현재 상황의 인식이 가능하다. 기존의 행위인지 기술은 사용자의 몸에 부착하여 데이터를 수집하는 웨어러블(Wearable) 센서를 활용하거나 움직임을 2D, 3D 카메라로 수집한 이미지를 분석하여 행위를 인지하는 연구가 주를 이루었다[1,2]. 움직임을 측정 가능한 가속도 센서, 위치를 얻어올 수 있는 GPS 혹은 주변 환경의 소리나 사용자 음성 등의 획득이 가능한 오디오 센서 등을 기반으로 하는 연구들이 많이 수행되었으나, 이들 연구는 단일 센서 데이터만을 기반으로 행위를 인지했다는 한계가 있다. 이 방법론은 라이프로그와 같이 하루 동안의 다양한 행위를 인지하는 데는 한계가 있다. 예를 들어, 걷기, 뛰기와 같은 단순하고 반복적인 행위는 가속도 센서 혹은 자이로스코프만을 가지고 인지할 수 있지만[3] 버스나 지하철과 같은 대중교통의 이용이나 대화 중, 회의 중과 같은 상황은 위치정보와 주변 오디오 데이터가 요구된다[4,5]. 따라서 사용자의 일상생활행위(ADL: Activities of Daily Life)의 인지가 요구되는 라이프로그 데이터는 단일 센서가 아닌 이기종의 다양한 센서 데이터가 복합적으로 처리되어야 한다.

스마트폰은 단일기기에 여러 센서 디바이스가 내장되어 있으며 기존 웨어러블 센서와 달리 자체적으로 데이터를 처리하고 저장할 수 있다. 또한 정보 수집을 위한 센서 뿐 아니라 마이크, 스피커, 터치스크린 등 사용자와 인터랙션을 위한 다양한 디바이스들이 내장되어 있어 사용자 행위 정보의 수집과 처리 그리고 서비스 제공을 위한 플랫폼으로 적절하다. 또한 라이프로그는 매우 개인화된 정보로써 개인의 특성을 고려한 인지가 이루어져야 하며 지속적, 실시간으로 수집되어야 하는데 스마트폰 환경에서는 위와 같은 요구사항을 만족한다.

기존의 행위인지 방법론은 인지하고자 하는 행위 샘플을 가지고 트레이닝(Training)을 거쳐 행위 모델(Model)의 구축과 이를 통해 새로운 행위를 인지(Recognition)하는 크게 두 개의 단계로 나뉜다. 확률 기반의 기존 알고리즘들은 방대한 샘플 데이터를 처리하여 행위 모델을 도출하므로 스마트폰과 같은 모바일 기기에서는 행위 모델링이 불가능하다는 한계가 있다. 또한 라이프로그와 같은 개인화된 데이터의 수집을 위해서는 기존의 평균화된 행위 모델을 도출하고 이를 다수의 사용자에게 적용하는 방법론이 아닌, 인지하고자 하는 특정 대상의 고유 행위 패턴과 특징을 트레이닝하고 그 대상에 특화된 행위 모델을 도출하는 방법론이 요구된다.

따라서 본 논문에서는 개인화된 라이프로그 수집을 위하여 사용자가 스스로 자신의 행위모델을 스마트폰과 같은 모바일 플랫폼에서 구축하고 인지할 수 있는 경량 행위 모델링 및 인지 알고리즘인 적응형 Naive Bayes (A-NB: Adaptive Naive Bayes) 알고리즘을 제안한다. 또한 제안하는 방법론을 기반으로 스마트폰에서 15개의 행위를 트레이닝하고 인지하는 계층적 행위인지 프레임워크(HARF: Hierarchical Activity Recognition Framework)를 제안하고 스마트폰 어플리케이션 형태로 개발하여 정확도와 유용성을 평가한다. 제안하는 프레임워크에서는 행위데이터 수집과 처리가 각기 다른 시스템에서 수행되는 것이 아닌 스마트폰 플랫폼에서 동시에 이루어지므로 데이터의 처리와 결과 도출이 실시간으로 수행된다.

본 논문은 다음과 같이 구성된다. 2장에서는 행위인지 관련 기존연구들을 소개하고 제안하는 기술과의 차별성과 한계를 제시하며, 3장에서는 Naive Bayes를 개선한 적응형 Naive Bayes를 서술한다. 4장에서는 A-NB를 기반으로 계층적 행위인지 프레임워크에 대해서 서술하며, 5장에서는 제안한 연구의 성능평가를 위해 스마트폰 어플리케이션으로 개발한 시스템을 사용하여 타 알고리즘과의 비교 및 정확도를 제시하고 6장에서 결론을 맺는다.

2. 관련 연구

2.1 스마트폰 멀티모달 센서 기반 행위인지

스마트폰의 멀티모달 센서를 활용하여 행위를 인지하는 방식은 다양한 센서 데이터를 하나의 모바일 기기에서 수집하고 처리할 수 있다는 점에서 많은 연구가 수행되고 있다. 스마트폰의 가속도센서를 사용하여 인간의 걷는 행위와 뛰는 행위를 인지하는 연구[3,6]와 GPS를 통해 사용자가 교통수단을 이용하는 패턴을 인지하는 연구[7,8]가 있다. 하지만 사용자의 행위를 스마트폰 센서를 활용하는 대부분의 연구들은 여러 센서들을 복합적으로 활용하는 것이 아닌 단일 센서만을 사용하므로, 인지할 수 있는 행위의 종류가 적으며 다양한 상황(물리적 움직임, 사용자 주변 상황 등)을 인지하기 어렵다. 스마트폰의 멀티모달 센서를 사용하여 상황을 인지한 연구에서는 다수의 센서를 사용하여 여러 행위 및 상황을 인지했다는 측면에서 본 논문과 비슷하나, 행위 모델링을 높은 리소스가 요구되는 HMM과 GMM 알고리즘을 사용하였다[9]. 그래서 모바일 환경이 아닌 오프라인에서 모델링이 수행되어 개인화된 행위인지의 한계가 있다. 한편 [2]의 연구에서는 행위인지 시 가속도 센서만 사용하지 않고 오디오 센서를 복합적으로 사용하는 경우 오디오 정보가 행위인지에 도움이 되는 것을 통해,

여러 개의 센서 데이터가 복합적으로 사용될 때 정확도가 향상되는 것을 증명하였다.

2.2 행위 모델링 및 행위인지 알고리즘

반면 다수의 가속도센서 혹은 이기종의 여러 센서들을 인지 대상자의 몸 여러 군데에 부착하여 행위를 인지하는 연구들이 이루어졌으나[10], 센서들이 케이블로 연결되어있어 라이프로그와 같이 장기간의 행위를 모니터링 하는 접근법에는 적절하지 않다. 가속도 데이터 분류에 관련해서 특징 추출(Feature extraction)과 분류(Classification) 과정에 관련된 다양한 연구가 있다[11]. SVM[6], 신경망[12,13], GMM[14], HMM[10]과 같은 기계학습 알고리즘을 기반으로 한 행위인지가 연구되었다. 특히 [15,16]과 같이 간단한 휴리스틱 방법론을 도입하여 행위를 분류하는 기술도 제안되었다. 이와 같은 기존 연구들은 행위 모델의 구축을 위한 트레이닝 과정에서 높은 시스템 리소스를 요구하여 스마트폰과 같은 모바일 기기에 적용이 어렵다는 단점이 있다.

3. 제안하는 적응형 Naive Bayes 알고리즘

본 논문에서는 Naive Bayes를 사용자 행위인지를 위한 기반 알고리즘으로 활용한다. 사용자 행위정보가 구축된 행위 모델들 중 특정 분류에 속할 확률을 계산하여 가장 높은 확률의 분류를 선택하여 행위를 인지한다. 스마트폰과 같은 모바일 기기에서 실시간으로 행위를 인지하기 위해서는 인식 방법이 빠르고 가벼워야 한다. [17]은 여러 분류기법 모델을 비교한 연구결과로써, Naive Bayes 분류기가 다른 기계학습 알고리즘 기반 분류 모델에 비해 매우 빠른 모델 생성시간을 보여준다. Naive Bayes 분류기가 모델을 생성하는데 빠른 장점이 있지만, 상대적으로 느린 처리속도, 작은 메모리와 같이 자원의 제약이 있는 모바일 환경에 적용하기에는 한계가 있다. 첫째, 샘플 데이터로부터 특징을 추출하여 행위 모델링을 하는 단계에서 센서로부터 수집된 수많은 데이터를 처리할 때 발생 가능한 메모리 오류다. 이는 특히 충분하지 못한 메모리와 데이터 처리 환경을 가진 모바일 시스템에서 발생한다. 둘째, Naive Bayes 알고리즘의 기본적인 가정 중의 하나인 모든 속성이 같은 중요도를 가진다는 가정은 Naive Bayes 분류기가 생성하는 사후(Posterior) 확률의 정확도를 떨어지게 하는 원인으로 작용한다. 위와 같이 모바일 환경에 적용하여 행위를 인지하는 경우 발생가능한 문제의 해결을 위하여 적응형 Naive Bayes 알고리즘을 제안한다.

3.1 Naive Bayes 분류기

Bayes 이론에 기초하고 있는 Naive Bayes 알고리즘은 통계 기반의 분류 방법으로 주어진 데이터가 특정 클래스에 속할 확률을 예측할 수 있다. 기존의 기계학습

알고리즘인 의사결정트리나 신경망 알고리즘과 비교해볼 때 대용량 데이터베이스에서 높은 정확성과 속도를 나타내며 HMM, GMM, SVM과의 비교에서는 상대적으로 빠른 처리 속도와 적은 리소스를 요구한다[18]. Naive Bayes 확률 모델은 F_1 부터 F_n 까지의 샘플 데이터가 독립적인 클래스 C 에 포함된다고 가정한다. $F_1 \dots F_n$ 의 샘플 데이터가 발생했을 경우 C 라는 가정이 발생할 확률은 $p(C|F_1, \dots, F_n)$ 으로 결정할 수 있으며 이를 사후확률이라 부른다. $p(C|F_1, \dots, F_n)$ 을 계산하기 위해서는 $p(F_1, \dots, F_n)$ 과 $p(C)$ 가 요구되며, 이들은 학습 데이터들을 통해서 측정이 가능하고 이를 경계확률이라 한다. Bayes의 정리를 사용하면 사후확률은 다음 식 (1)으로 정의할 수 있다.

$$p(C|F_1, \dots, F_n) = \frac{p(C)p(F_1, \dots, F_n|C)}{p(F_1, \dots, F_n)} \quad (1)$$

$p(F_1, \dots, F_n)$ 는 모든 클래스에 대해 일정한 값을 가지므로, 오직 $p(C)p(F_1, \dots, F_n|C)$ 만을 최대화하도록 고려한다. 만약 클래스의 경계확률을 알 수 없다면 $p(F_1, \dots, F_n|C)$ 만을 고려할 수 있다. $p(F_1, \dots, F_n|C)$ 는 Naive Bayes의 독립가정에 의해 계산하며, 그 결과 $F_1 \dots F_n$ 은 가장 큰 사후 확률을 가지는 클래스로 분류할 수 있다. 따라서 구하고자 하는 사후확률은 다음 식 (2)로 정의된다.

$$V_{\max} = p(C_j|F_1, \dots, F_n) = p(C) \prod_{i=1}^n p(F_i|C) \quad (2)$$

위의 식 (2)에서 C 는 주어진 샘플이 클래스 j 일 확률, F_i 는 i 번째 속성일 확률, $p(C)$ 는 전체집합에서 클래스 C 가 속할 확률, $p(F_i|C)$ 는 클래스 C 에서 특정 속성일 확률을 나타내며, 각 클래스를 계산하여 가장 큰 사후확률 값 V_{\max} 가 선택된다.

한편, 샘플 데이터인 F_i 가 몇 개의 한정된 값들 중 하나를 값으로 갖는 분류 속성이라면 $p(F_i|C)$ 의 계산은 트레이닝 데이터로부터 고전적 확률 공식으로 쉽게 구할 수 있지만, 행위 인지를 위한 트레이닝 데이터는 대부분이 연속적인 실수값을 가진다. 이러한 경우에 조건부 확률을 구하기 위해서는 확률 분포를 사용하여야 하며 클래스 C 의 F_i 값들에 대한 평균을 μ_c 라 하고 분산을 σ_c^2 라 할 때, F_i 의 분포를 나타내기 위해 다음 식 (3)과 같은 가우시안 분포를 사용한다.

$$P(F_i = v|C) = \frac{1}{\sqrt{2\pi\sigma_c^2}} e^{-\frac{(v-\mu_c)^2}{2\sigma_c^2}} \quad (3)$$

3.2 제안하는 A-NB 알고리즘

본 논문에서는 단일 센서가 아닌 복수의 센서 디바이

스가 내장된 스마트폰을 기반으로 행위를 인지하기 때문에, 자원이 제약된 환경에서 여러 센서로부터 수집되는 방대한 행위 데이터를 처리할 수 있는 경량 알고리즘이 요구된다. 또한 Naive Bayes 알고리즘의 특징인 고려하는 모든 속성이 같은 중요도를 가진다는 가정으로 인해 타 분류 알고리즘보다 낮은 정확도를 가지는 한계가 있다. 따라서 본 절에서는 스마트폰 환경에서 행위 모델링 및 인지가 가능한 Naive Bayes 알고리즘 기반 경량 분류 알고리즘인 A-NB를 제안한다.

Naive Bayes를 사용하여 행위 모델의 구축 시 샘플 데이터 수 i 의 양에 따라 모델링 계산량이 결정되며, 고려하는 요소가 많을 경우 식 (3)에 기술된 데이터 F_i 의 평균 μ_c 과 분산 σ_c^2 을 구하는 과정에서 엄청난 데이터가 한 번에 처리된다. 데이터 처리를 위한 메모리 및 캐시가 충분한 서버환경에서는 문제가 되지 않으나 자원이 극히 제한적인 모바일 환경에서는 메모리 오버플로우(Overflow) 문제가 발생한다. 이는 행위인지 서비스의 오류 뿐 아니라 모바일 시스템 전체의 서비스 지연과 같은 시스템 관리 문제점을 야기한다. 이는 소수의 센서 데이터만을 가지고 분류를 수행하는 경우에는 영향을 받지 않으나 인지의 정확도가 떨어진다는 단점이 있다. 반면에 다수의 센서를 사용하는 경우 고려하는 요소가 많아져 비슷한 행위들 간의 구분이 어려워진다는 단점이 있다. 예를 들어 걷기, 뛰기, 서기와 같이 위치 및 주변 상황정보가 아닌 가속도 센서로 수집 가능한 물리적인 움직임을 인지하는 경우, 가속도센서 외 GPS, 근접센서, 조도센서, 마이크 등 관련 없는 센서 데이터들까지도 동일한 가중치를 가지고 평가하게 되어 정확도가 낮아진다.

따라서 위와 같이 모바일 환경에서 행위를 인지하는 경우 발생가능한 문제의 해결을 위하여 A-NB 알고리즘을 제안한다. A-NB는 실시간 행위 트레이닝 과정에서 발생하는 메모리 오버플로우(Overflow)의 해결을 위해, F_i 의 평균과 분산 값을 트레이닝을 마친 후 한 번에 구하지 않고 특정시간구간 t 마다 평균과 제곱평균 그리고 분산을 구한다. 평균과 분산을 구하는 과정에서 메모리 효율 및 성능을 고려하여 제곱평균을 추가하는 방식을 제안하였으며 평균과 제곱평균 그리고 분산을 구하는 재귀식은 다음 식 (4)와 같다.

$$\begin{aligned}\mu_N &= \frac{\mu_{(N-1)} \times (N-1) + F_N}{N} \\ \nu_N &= \frac{\nu_{(N-1)} \times (N-1) + F_N^2}{N} \\ \sigma_N^2 &= \nu_N - \mu_N^2\end{aligned}\quad (4)$$

위의 식 (4)에서 N 은 특정시간구간 t 동안 수집된 데이터의 개수이며 μ_N 은 N 개의 데이터에 대한 평균, ν_N

은 N 개의 데이터의 제곱에 대한 평균 그리고 σ_N^2 은 분산을 나타낸다. 전체 트레이닝 시간동안 j 개 만큼 평균과 분산이 구해졌으면, F_i 는 다음 식 (5)와 같은 행렬을 가진다.

$$\{(\mu_1, \sigma_1^2), (\mu_2, \sigma_2^2), (\mu_3, \sigma_3^2), \dots, (\mu_j, \sigma_j^2)\} \quad (5)$$

여기서 j 는 시간구간의 개수이다. 식 (4)의 행렬을 가지고 Naive Bayes에 적용한다. 제안하는 A-NB는 첫 번째 시간 t 만큼 구해진 평균값 μ_1 부터 μ_j 까지의 평균값 μ_m 을 전체 샘플의 평균값으로, 동일한 시간동안 수집된 분산 값 σ_1^2 부터 σ_j^2 까지의 평균값 μ_v 를 전체 샘플의 분산 값으로 식 (2)에 적용하여 사후확률을 구한다. 새로 구해진 사후확률은 식 (6)과 같다.

$$V'_{\max} = p(C_j | F_1, \dots, F_n) = p(C) \prod_{i=1}^n p'(F_i | C) \quad (6)$$

제안하는 A-NB는 $p'(F_i | C)$ 의 값을 구하기 위하여 식 (3)은 다음 식 (7)과 같이 변경된다.

$$P'(F_i = v | C) = \frac{1}{\sqrt{2\pi\mu_v}} e^{-\frac{(v - \mu_m)^2}{2\mu_v}} \quad (7)$$

여기서 μ_m 은 평균 $\mu_1 \dots \mu_j$ 의 평균값이며 μ_v 는 분산 $\sigma_1^2 \dots \sigma_j^2$ 의 평균값이다. 따라서 스마트폰을 통해 행위 모델링 시 실시간으로 데이터 샘플 F_i 에 대한 평균과 분산을 구할 수 있으며 이를 식 (6)과 (7)에 대입하여 사후확률 $P'(F_i = v | C)$ 와 V'_{\max} 를 구할 수 있다.

4. 제안하는 계층적 행위인지 프레임워크

4.1 제안하는 HRF 방법론

멀티모달 센서를 통해 행위를 인지하는 방법론은 인지 가능한 행위의 수를 늘리고 다양한 상황을 인지할 수 있으나, 입력 값이 증가하여 행위 분류기가 고려해야 하는 값이 늘어나고 이로 인해 정확도가 떨어지는 현상이 발생한다. 이와 같은 단점의 극복을 위해 계층적으로(Hierarchical) 행위를 분류하는 방법론인 HRF를 제안한다. 라이프로그는 단순 행위의 인지 뿐 아니라 특정 장소의 방문, 물리적 행위 외 차량의 탑승 등 다양한 종류의 행위를 포함한다. 또한 동일한 행위가 인지되더라도 장소에 따라 의미가 달라질 수 있는 데 착안하여 크게 3가지로 행위를 분류한다.

첫 번째 카테고리는 위치 및 물리센서 데이터에 기반한 행위들로, 1차로 행위가 발생한 위치를 GPS 데이터를 통해 인지하여 등록된 지점(Indoor-집 혹은 사무실)일 경우 각 위치에서 3개의 행위(걷기, 앉기, 서기)를 인지한다. 위치가 등록된 지점이 아닐 경우(Outdoor) 4개의 행위(걷기, 앉기, 서기, 뛰기)를 인지한다. 인지에 사

용되는 센서는 물리적인 움직임을 인지하기 위한 가속도 센서와 자이로스코프, 스마트폰의 소리 위치를 인지하기 위한 근접센서 그리고 위치정보를 얻어오기 위한 GPS 센서이다. 두 번째 카테고리인 위치기반 행위로는 특정 장소에 가거나 머무는 행위들로 개인화된 라이프로그 수집을 위해 중요한 정보들이다. 마지막 카테고리는 휴리스틱 기반 행위로서 위치와 물리적인 움직임 외에 GPS 센서에서 획득 가능한 정보(이동속도, 방향, 고도 등)로 사용자가 자동차나 버스를 탑승하고 있는지 인지한다. 휴리스틱 방법론의 부재 시 교통수단을 타고 이동하는 경우 잠깐 멈춰서거나 느린 속도로 이동하는 경우 서기나 앉기 등으로 인지되는 오류가 발생하기 쉽다. 이를 방지하기 위해 제안하는 방법론은 교통수단으로 인지하고 난 뒤 잘못 인지될 수 있는 다양한 상황에 대해 룰을 생성하고 오류를 줄인다. 표 1은 카테고리 별 행위를 분류하고 각 행위를 인지하는 데 사용한 센서를 나열한다.

그림 1은 A-NB 알고리즘에 기반 하여 실시간으로 행위가 인지되는 제안하는 HARF의 구조도이다. A-NB를 행위 인지에 적용하는 경우, 표 1을 통해 분류한대로 행위를 우선 위치정보를 기반으로 분류하고 교통수단 이동의 경우 휴리스틱 방법론을 추가로 적용하여 인지하였다. 인지가 수행되면 사용자의 현재 위치가 등록된 위치인지 아닌지 판단한 후, 등록된 위치인 경우 그 위치가 Home과 Office인 경우에는 물리적인 움직임을 인

표 1 계층적 행위인지를 위한 특징에 따른 행위분류
Table 1 Activity categorization for hierarchical activity recognition

Type	Area	Activity	Sensors
Location & Multimodal sensor based activity recognition	Home	Walking	Accelerometer, Gyroscope, Proximity and GPS
		Sitting	
		Standing	
	Office	Walking	
		Sitting	
		Standing	
	Outdoor	Walking	
		Sitting	
		Standing	
Jogging			
Location based activity recognition	Outdoor	Waiting bus at bus stop	GPS
		Having a meal at cafeteria	
		Exercising at gym	
		Visiting a park	
Heuristic based activity recognition	Outdoor	Riding a car	Accelerometer, Gyroscope, Proximity, GPS and Heuristic Rule

지하며 그 외 위치인 경우 GPS데이터만을 사용하여 위치를 인지한다. 반면 사용자가 등록되어있지 않는 곳에 있다면 Outdoor임을 인지하고 이에 해당하는 물리적인 움직임을 인지한다. 제안하는 HARF에서 적용한 휴리스틱 방법론은 사용자의 위치가 등록된 리스트에 없을 경우 멀티모달 센서를 통해 물리적인 움직임을 인지하는 과정에서 이동속도가 25km/h가 넘어가는 경우에는 물리적인 움직임이 아니라고 판단하고 이를 자동차를 사용한 이동으로 인지한다. 이 경우 잠시 정차하는 경우나 인간의 이동속도와 비슷한 느린 속도로 이동하는 경우 교통수단을 이용하지 않는 것으로 오인시킬 수 있는 경우가 발생하므로, 일정 시간 동안 인지를 보류하거나 지연하는 방식의 휴리스틱한 룰을 적용한다. 이와 같은 방법론을 적용함으로써 기존 알고리즘을 보완하고 정확도를 향상시킨다.

4.2 HARF 기반 실시간 행위인지 시스템 구현

본 장에서는 스마트폰 환경에 적용하여 제안 알고리즘의 검증을 위한 실시간 행위 트레이닝 및 인지 시스템 (pARNL: Personalized Activity Recognizer and Logger)을 기술한다, pARNL은 개인화된 행위 인지와 라이프로그가 가능하며 스마트폰의 터치 디스플레이를 통해 센서를 모니터링하거나 개인화된 행위 모델을 추가할 수도 있다. pARNL은 그림 2와 같이 4개의 세부모듈로 구성되어 있으며 각각의 역할은 다음과 같다.

- Embedded Multimodal Sensors: 스마트폰에 내장된 다양한 센서 디바이스 중 행위인지를 위해 사용되는 4개의 센서(3축 가속도센서, 3축 자이로스코프, 근접센서, GPS)로 구성됨.
- Pre-processing: 멀티모달 센서로부터 일정 시간(50Hz) 간격으로 센싱 데이터를 수집하고 서로 다른 데이터 형을 통일시켜 데이터 처리 및 저장이 용이하게 함. 또한 행위 모델링 및 인지에 요구되는 특징(Feature)들을 수집한 센서 데이터로부터 추출함.
- Activity Training & Recognition: 본 논문에서 제안하는 H-NB 알고리즘 기반의 행위 트레이닝과 행위인지 모듈로 구성되며, 행위 트레이닝을 통해 도출된 행위 모델과 사용자가 직접 정의한 행위들을 저장하는 저장소(Repository)로 구성됨.
- User Interface: 멀티모달 센서로부터 수집되는 값을 사용자가 모니터링할 수 있게 하며 3축 가속도센서 값을 그래프로 표현하여 행위에 따른 데이터 값의 변화를 시각화하여 보여줌. 또한 사용자가 자신의 행위를 트레이닝하고 추가할 수 있는 인터페이스도 제공함.

5. 성능평가

제안하는 A-NB 알고리즘과 HARF의 검증 및 실험

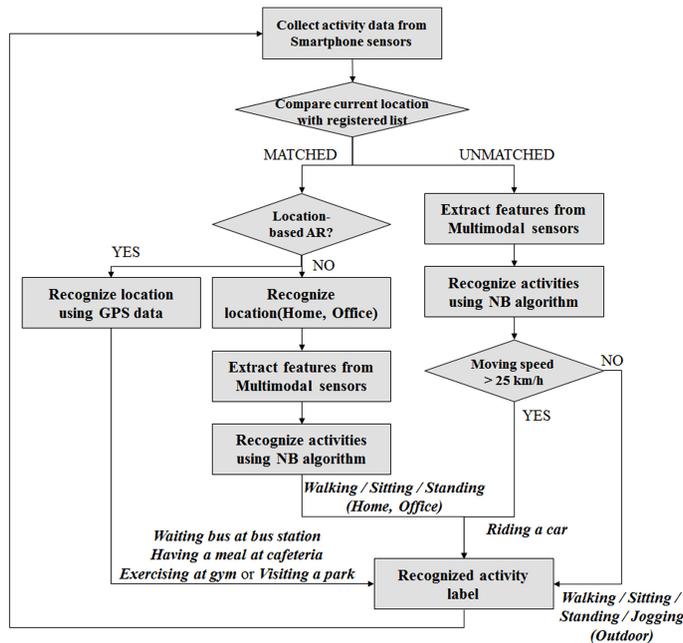


그림 1 인지 정확도 향상을 위한 제안하는 A-NB 알고리즘 기반 계층적 행위인지 프레임워크
 Fig. 1 A-NB based hierarchical activity recognition framework for enhancing a recognition accuracy

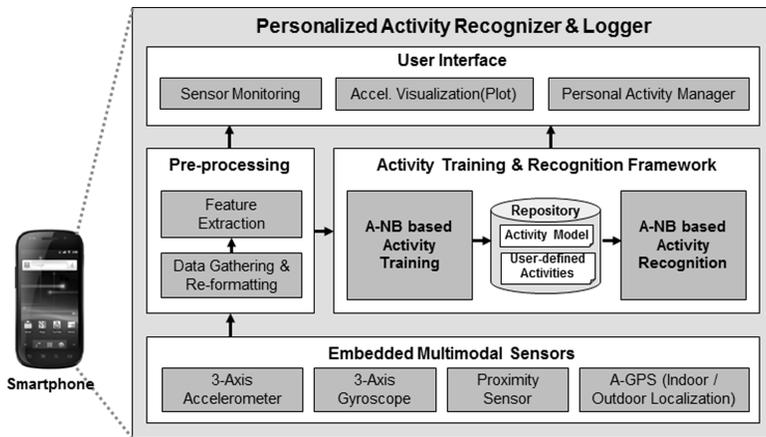


그림 2 HARF 기반 실시간 행위인지 시스템
 Fig. 2 HARF based real-time activity recognition system

을 위해 실시간 행위인지 시스템을 안드로이드 OS를 사용하는 스마트폰에 앱의 형태로 구현하였다. 앱 형태의 구현은 본 논문에서 사용한 특정 플랫폼 뿐 아니라 안드로이드 OS를 사용하는 다양한 스마트폰과 모바일 디바이스에 손쉽게 설치 가능하다는 장점이 있다. 또한 스마트폰의 다양한 UI(터치스크린, 키보드, 소리 등)은 사용자가 자신의 행위를 직접 모델링하거나 자신만의 행위를 추가할 수 있는 환경을 제공한다. 개발한 스

마트폰 앱은 그림 3과 같이 Android 2.3.3버전(API level 10)을 기준으로 구현하였으며 테스트를 한 기기는 삼성 Nexus S와 Galaxy S3 모델이었다.

표 2는 개발한 pARNL 앱을 사용하여 행위인지를 수행한 결과를 보여준다. 실제 특정 위치를 방문한 행위 4개 (Waiting bus at bus stop, Having a meal at cafeteria, Exercising at gym, Visiting a park)를 포함한 15개의 행위에 대해 실험을 하였으나, GPS를 사용하여 위치 정

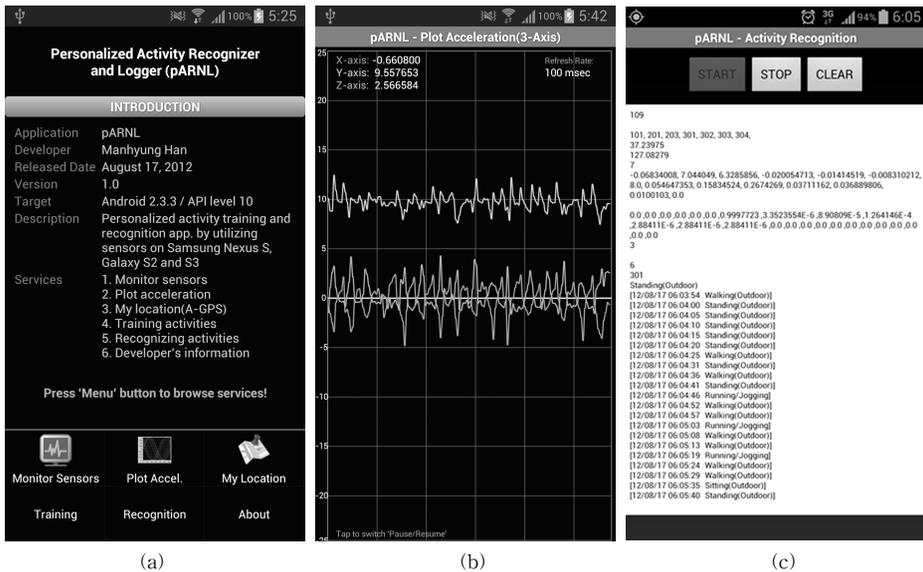


그림 3 실시간 행위인지 시스템을 구현한 스마트폰 앱. (a)는 앱의 초기화면으로 센서 값 모니터링, 가속도 값 시각화, 행위 트레이닝 및 인지 UI 제공. (b)는 걷기 행위의 경우 3축 가속도 센서 값을 시각화 함. (c) 행위인지 결과 스크린 샷

Fig. 3 Smartphone application which implementing real-time activity recognition framework. (a) Initial state of application. Sensor monitoring, accelerometer visualization, UI for activity training & recognition. (b) Visualizing 3-axis accelerometer values of walking activity. (c) Screenshot of activity recognition results

표 2 제안하는 HARF의 검증을 위한 11개의 행위에 대한 행위인지 정확도

Table 2 Activity recognition accuracy table of 11 activities for validating proposed HARF

Location	Activity	Home			Office			Outdoor				
		Standing	Walking	Sitting	Standing	Walking	Sitting	Standing	Walking	Sitting	Jogging	Car
Home	Standing	90.32	-	9.68	-	-	-	-	-	-	-	-
	Walking	10.43	83.47	6.1	-	-	-	-	-	-	-	-
	Sitting	2.56	-	98.44	-	-	-	-	-	-	-	-
Office	Standing	-	-	-	95.2	-	4.8	-	-	-	-	-
	Walking	-	-	-	4.84	94.35	0.81	-	-	-	-	-
	Sitting	-	-	-	1.2	0.61	98.19	-	-	-	-	-
Outdoor	Standing	-	-	-	-	-	-	94.34	-	5.66	-	-
	Walking	-	-	-	-	-	-	12.77	80.85	6.38	-	-
	Sitting	-	-	-	-	-	-	2.5	-	97.5	-	-
	Jogging	-	-	-	-	-	-	2.17	10.86	1.47	85.5	-
	Car	-	-	-	-	-	-	16.25	6.25	1.25	-	76.25

보를 통해 특정 장소를 인지하는 실험은 99.5% 이상의 정확도를 보였다. 실제 실험에서 단 1회의 오작동이 있었으나, 보통의 경우 실외에서 스마트폰의 GPS가 정상적으로 작동하므로 특정장소 방문은 아무 문제가 없었다. 따라서 표 2는 특정장소 인지를 제외한 11개의 행위에 대한 실험 결과이다.

15개의 행위에 대한 실험결과 평균 92.96%의 높은 정확도를 보였으며, 위치로만 행위를 인지한 4개의 행위를 제외한 11개의 행위에 대한 평균 정확도는 90.4%였

다. 실험 결과 중에 동일 행위이지만 행위가 발생한 장소에 따라 정확도의 차이가 난 경우가 있었다. 이는 환경에 따라 행위의 형태가 달라진 것을 보여주며, 특히 걷기(Walking)의 경우 실험을 진행한 실험실(Office)에서는 직선의 복도와 탁 트인 환경에서 실험 데이터를 모집한 반면 집(Home)과 야외(Outdoor)에서는 지속적으로 직선으로 걸을 수 없는 환경으로 인해 서기(Standing)으로 잘못 인지되는 경우가 빈번히 발생되었다. 하지만 서기와 앉기 행위의 경우 행위의 특성이 매우 정적이어

서 상대적으로 높은 인식률을 보였다. 그리고 뛰기(Jogging)의 경우 그 행위의 특성이 비슷한 걸기로 인지되는 경우가 10% 이상 발생되었으며, 교통수단(Car)을 인지하는 경우에도 중간에 차가 정지하거나 서행하는 경우 잘못 인지되는 경우가 있었다. 그림 4는 11개의 행위에 대한 인지결과를 표 2에 기반하여 True Positive와 False Negative를 나타낸 그래프이다.

반면, 제안하는 HARF와 기반 알고리즘인 Naive Bayes의 성능비교는 다음 그림 5와 같다. 15개의 행위에 동일한 환경에서 성능평가를 실시한 결과, Naive Bayes 알고리즘은 평균 81.17%의 결과를 보인 반면 제안하는 HARF는 89.88%의 정확도를 보였다. 성능평가지 비교적 높은 결과를 보인 서기, 앉기, 뛰기, 특정장소 방문의 행위는 HARF와 기존 Naive Bayes 두 실험 모두에서 90% 내외의 좋은 결과를 내었으나, 교통수단을 사용하는 행위(Car Driving)에 대해서는 HARF는 76%의 정확도를 얻었으나 Naive Bayes 알고리즘을 사용한 경우에는 50%의 매우 낮은 정확도를 보였다.

제안 알고리즘의 평가를 위해 정확도 뿐 아니라 행위 인지의 속도도 고려하였으나 실험환경인 스마트폰과 연구PC에서 사용자의 행위인지는 수 ms 이하의 속도로 매우 빠르게 처리되었다. 다수의 센서 뿐 아니라 다수의 사용자의 데이터를 복합적으로 처리해야하는 빅데이터 처리 환경에서는 인지의 정확도 뿐 아니라 처리속도도 중요하다. 하지만 본 연구는 스마트폰 사용자의 행위 모델을 생성하고 수집되는 센서 데이터를 통해 그 모델에 의한 결과 값을 도출하는 방법론을 제시하였으므로 향후 다수의 사용자로부터 수집된 데이터를 복합적으로 처리하는 연구의 경우 처리속도도 고려해야 할 것이다.

또한 기존의 유사 연구와의 비교는 제안하는 방법론이 스마트폰 플랫폼에서 데이터 수집과 처리가 모두 수행되는 구조로써, 기존의 방법론인 스마트폰에서 수집된 데이터를 강력한 시스템 리소스가 가용한 PC환경에서 행위 트레이닝과 모델링을 수행한 결과와 직접적인 비

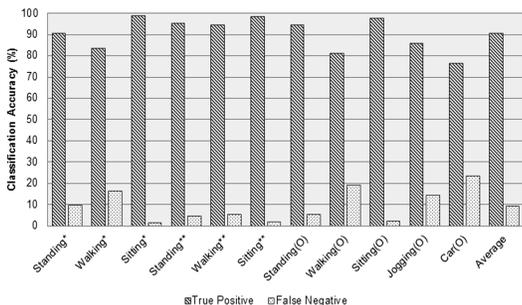


그림 4 11개의 행위에 대한 행위인지 정확도 그래프
Fig. 4 Activity recognition accuracy graph of 11 activities

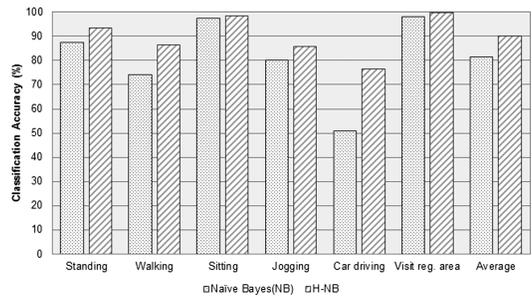


그림 5 15개의 행위에 대한 Naive Bayes와 제안하는 HARF와의 인지 정확도 비교

Fig. 5 Accuracy comparison between Naive Bayes and HARF for 15 activities

교는 불가능하다. 기존 연구[9]는 행위인지 정확도에 가장 큰 영향을 미치는 행위 모델링을 HMM알고리즘을 사용하였으며 모든 인지 가능한 행위(걸기, 뛰기, 서기, 버스 및 지하철 탑승)에서 90%가 넘는 결과를 내었다. 하지만 본 연구는 개인화된 모델링 및 실시간 인지를 위해 스마트폰 플랫폼에서 모든 데이터가 처리되고 결과가 도출되는 접근법을 채택하여 유사연구에서 인지한 행위에 대해 평균 85.32%의 비교적 낮은 결과를 내었다. 이는 제안한 연구가 스마트폰과 같은 모바일 플랫폼이 가지는 상대적으로 적은 리소스를 가지고 기존의 강력한 PC 및 서버 환경에서 얻을 수 있는 결과에 버금가는 결과를 도출하였음을 뜻한다.

5. 결론 및 향후연구

본 논문에서는 스마트폰의 멀티모달 센서를 기반으로 사용자의 의도나 요구사항을 파악하기 위한 개인화된 행위 모델링 및 실시간 행위인지 기술을 제안하였다. 자원의 제약이 있는 스마트폰과 같은 모바일 플랫폼 상에서 자신의 고유 행위를 모델링하고 인지하기 위해 Naive Bayes 알고리즘에 기반한 A-NB 알고리즘과 계층적 행위인지 프레임워크인 HARF를 제안하였다. A-NB 알고리즘과 HARF는 모바일 환경에서 방대한 멀티모달 센서데이터 처리 시 발생할 수 있는 메모리 오버플로우에 대한 해결과 Naive Bayes의 특징인 낮은 정확도의 보완을 위해 계층적 행위 모델링 및 행위인지 방법론을 적용하였다. 이를 통해 스마트폰이 제공하는 인터페이스를 통해 사용자가 스스로 자신의 행위를 모델링하거나 추가할 수 있으며, 계층적 행위인지로 15개의 각기 다른 행위에 대한 높은 분류 정확도를 보였다. 제안 기술의 성능평가를 위해 HARF에 기반한 스마트폰 어플리케이션인 pARNL을 개발하였다. pARNL은 안드로이드 OS 환경에서 구동 가능한 스마트폰 앱으로 센서 데이터 모

니터링과 자가 행위 트레이닝 그리고 행위인지 기능 등으로 구성된다. pARNL로 15개의 다양한 행위들에 대한 행위인지를 수행한 결과 92.96%의 높은 정확도를 보였으며 Naive Bayes와의 비교 실험에서도 HARF가 10.73% 더 높은 인지 정확도를 보였다.

제안하는 HARF는 상대적으로 단순하고 패턴이 일정한 행위들(뛰기, 서기 등)에서는 높은 정확도를 보였으나 대중교통의 이용이나 사용자에 따라 다양한 패턴이 있을 수 있는 건기 행위에 대해서는 낮은 정확도를 보였다. 이를 보완하기 본 논문에서 활용한 스마트폰 센서들 뿐 아니라 오디오 센서로부터 수집된 주변 소음이나 외부 센서를 복합적으로 고려한 행위인지 연구가 요구된다. 다양한 멀티모달 센서 데이터의 활용과 이들 데이터의 복합적인 처리는 행위 모델링과 행위 인지의 정확도를 높일 수 있을 것으로 기대된다.

참 고 문 헌

- [1] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, "Activity Recognition using Cell Phone Accelerometers," *ACM SIGKDD Explorations Newsletter*, vol.12, pp.74-82, 2010.
- [2] J. A. Ward, P. Lukowicz, G. Troster, and T. Starner, "Activity Recognition of Assembly Tasks using Body-Worn Microphones and Accelerometers," *Pattern Anal. Mach. Intell. IEEE Transactions on*, vol.28, pp.1553-1567, 2006.
- [3] A. M. Khan, Y. Lee, S. Y. Lee, and T. Kim, "A Triaxial Accelerometer-Based Physical-Activity Recognition Via Augmented-Signal Features and a Hierarchical Recognizer," *IEEE Transactions on Information Technology in Biomedicine*, vol.14, no.5, pp.1166-1172, 2010.
- [4] H. Lu, W. Pan, N. D. Lane, T. Choudhury, and A. T. Campbell, "SoundSense: Scalable Sound Sensing for People-Centric Applications on Mobile Phones," In *Proceedings of the 7th International Conference on Mobile Systems, Applications, and Services*, pp.165-178, 2009.
- [5] L. Liao, D. Fox, and H. Kautz, "Location-Based Activity Recognition," In *Advances in Neural Information Processing Systems*, pp.787-794, 2005.
- [6] N. Ravi, N. Dandekar, P. Mysore, and M. L. Littman, "Activity Recognition from Accelerometer Data," In *Proceedings of the Seventeenth Conference on Innovative Applications of Artificial Intelligence*, pp.1541-1549, 2005.
- [7] L. Liao, D. Fox, H. Kautz, "Extracting Places and Activities from GPS Traces using Hierarchical Conditional Random Fields," *Int.J.Rob.Res.*, vol.26, pp.119-134, 2007.
- [8] L. T. Vinh, S. Y. Lee, Y. T. Park, B. d'Auriol, "A Novel Feature Selection Method Based on Normalized Mutual Information," *Appl. Intell.*, vol.37, pp.100-120, 2012.
- [9] M. Han, L. T. Vinh, Y.-K. Lee and S. Lee, "Comprehensive Context Recognizer Based on Multimodal Sensors in a Smartphone," *Journal of Sensors*, vol.12, no.9, pp.12588-12605, 2012.
- [10] D. Minnen, T. Starner, J. Ward, P. Lukowicz, and G. Troester, "Recognizing and discovering human actions from on-body sensor data," in *Proc. IEEE Int. Conf. Multimedia Expo*, pp.1545-1548, 2005.
- [11] K. Q. Shen, C. J. Ong, X. P. Li, and E. P. V. Wilder-Smith, "Novel Multi-Class Feature Selection Methods using Sensitivity Analysis of Posterior Probabilities," In *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, pp.1116-1121, 2008.
- [12] J. Mantyjarvi, J. Himberg, and T. Seppanen, "Recognizing human motion with multiple acceleration sensors," in *Proc. IEEE Int. Conf. Syst., Man, Cybern.*, vol.2, pp.747-752, 2001.
- [13] D. Giansanti, V. Macellari, and G. Maccioni, "New neural network classifier of fall-risk based on the Mahalanobis distance and kinematic parameters assessed by a wearable device," *Physiol. Meas.*, vol.29, pp.N11-N19, 2008.
- [14] F. Allen, E. Ambikairajah, N. Lovell, and B. Celler, "Classification of a known sequence of motions and postures from accelerometry data using adapted gaussian mixture models," *Physiol. Meas.*, vol.27, pp.935-951, 2006.
- [15] B. Najafi, K. Aminian, A. Paraschiv-Ionescu, F. Loew, C. J. Bula, and P. Robert, "Ambulatory system for human motion analysis using a kinematic sensor: Monitoring of daily physical activity in the elderly," *IEEE Trans. Biomed. Eng.*, vol.50, no.6, pp.711-723, 2003.
- [16] M. Mathie, B. Celler, N. Lovell, and A. Coster, "Classification of basic daily movements using a triaxial accelerometer," *Med. Biol. Eng. Comput.*, vol.42, pp.679-687, 2004.
- [17] C. Kim, K.-B. Hwang, "Comparative Study of Machine Learning Techniques for Spammer Detection in Social Bookmarking Systems," *Journal of KIISE : Computing Practices and Letters*, vol.15, no.5, pp.345-349, May 2009. (in Korean)
- [18] C.-H. Lee, "An Information-theoretic Approach for Value-Based Weighting in Naive Bayesian Learning," *Journal of KIISE : Databases*, vol.37, no.6, pp.285-291, Dec. 2010. (in Korean)



한 만 형

2005년 경희대학교 컴퓨터공학과 학사
 2007년 경희대학교 컴퓨터공학과 석사
 2007년~현재 경희대학교 컴퓨터공학과
 박사과정. 현재 경희대학교 동서신의학
 u-라이프케어 연구센터 연구원. 관심분
 야는 유비쿼터스 컴퓨팅, 상황인지, 행위

인지, 인공지능



이 승 통

1978년 고려대학교 재료공학과 공학사
 1987년 Illinois Institute of Technology
 전산학과 석사. 1991년 Illinois Institute
 of Technology 전산학과 박사. 1992년~
 1993년 Governors State University,
 Illinois 조교수. 1993년~현재 경희대학
 교 전자정보학부 컴퓨터공학과 교수. 현재 경희대학교 동서
 신의학 u-라이프케어 연구센터 센터장. 관심분야는 유비쿼
 터스 컴퓨팅, 상황인지, 인공지능, 실시간 시스템, 미들웨어
 시스템, 보안, 클라우드 컴퓨팅