

u-라이프케어를 위한 HMM 기반의 분산 행위 인지 알고리즘

김홍섭*, 임거수**

A Distributed Activity Recognition Algorithm based on the Hidden Markov Model for u-Lifecare Applications

Hong-Sop Kim *, Geo-Su Yim **

요 약

본 논문에서는 일상 공간에서 발생할 수 있는 인간의 일상생활 행위(ADL: Activities of Daily Living)들을 인지하는 분산 모델을 제시한다. 사용자의 환경, 위치 및 행위 정보를 간단한 센서들이 부착된 가정용 기기 혹은 식기들을 통해 무선 센서 네트워크로 수집하며 분석하고, 이 정보를 기반으로 사용자의 생활패턴, 건강상태 등을 파악하여 이에 요구되는 라이프케어 서비스를 제공한다. 하지만 서비스의 제공을 위해서는 높은 수준의 행위 인지 데이터가 요구되나 충분히 분석되어지지 않은 센싱 데이터들은 고차원 상황 추론을 위한 일상생활 행위 인지 모델의 구축을 어렵게 한다. 그러나 수집 데이터의 순서를 통해 행위를 인지할 수 있다는 것에 착안하여 센서 데이터들의 순서를 특정 행위 패턴을 분석하는 데 활용하고, 이를 기반으로 한 분산 선형 시간 추론 알고리즘을 제안한다. 이 알고리즘은 가정, 사무실 및 병원과 같은 소규모 환경에서 행위를 인지하는 데 적절하다. 제안한 알고리즘의 성능평가를 위해서 MIT Media Lab에서 제공하는 공개 데이터를 사용하였으며, 75% 이상의 평균 행위 인지 정확도를 보였다.

Abstract

In this paper, we propose a distributed model that recognize ADLs of human can be occurred in daily living places. We collect and analyze user's environmental, location or activity information by simple sensor attached home devices or utensils. Based on these information, we provide a lifecare services by inferring the user's life pattern and health condition. But in order to provide a lifecare services well-refined activity recognition data are required and without enough inferred information it is very hard to build an ADL activity recognition model for high-level situation awareness. The sequence that generated by sensors are very helpful to infer the activities so we utilize the sequence to analyze an activity pattern and propose a distributed linear time inference algorithm. This algorithm is appropriate to recognize activities in small area like home, office or hospital. For performance evaluation, we test with an open data from MIT Media Lab and the recognition result shows over 75% accuracy.

• 제1저자 : 김홍섭 교신저자 : 임거수

• 투고일 : 2009. 04. 24, 심사일 : 2009. 05. 07, 게재확정일 : 2009. 05. 20.

* 오산대학 멀티미디어정보과 부교수 ** 배재대학교 과학기술학부 전임강사

※ 이 논문은 2009년 한국컴퓨터정보학회 제 39차 동계학술대회에서 발표한 논문("WSN환경에서 은닉 마코프 모델 기반의 분산추론 기법을 적용한 행위 인지 알고리즘")을 확장한 것임

▶ Keyword : 분산 행위 인지(Distributed Activity Recognition), 일상생활 행위(ADL: Activities of Daily Living), 분산 추론(Distributed Inference), 은닉 마코프 모델(Hidden Markov Model)

1. 서론

유비쿼터스 헬스케어 환경에서 식사를 준비하거나 목욕을 하는 것과 같은 사용자의 일상생활 행위(ADL)를 인지하는 것은 필수요소이다[1]. 또한 가정에서 일상 행위들을 인지하고 모니터링 하는 것은 프로액티브 헬스케어 서비스를 제공할 수 있다[2]. 특히 모니터링 서비스는 환자의 건강상태에 대한 지속적인 관리 및 질병변화 추이에 대한 기록을 관리해 줌으로써, 향후 높은 경제적인 위험을 가져다 줄 수 있는 상황으로의 변화를 막아준다.

ADL들을 인지하기 위해서는 다양한 가정용 기기들이 사용된다. 이 기기들과 도구들은 특정 사용자의 일정한 습관이나 패턴에 의해 사용되며, 동일한 기기를 가지고도 각 사용자마다 서로 다른 사용패턴을 가진다. 이 행위의 다양성으로 인해 일정 시간 안에 충분히 분석되고 혼란되어지지 못할 경우 일정한 행위 모델의 구축이 매우 어렵게 된다[3]. 게다가 동일한 행위를 반복하더라도 하더라도 매번 행위 순서나 시간이 다르게 나타날 수 있고 어떤 행위가 특정 목적을 가지는지 확신할 수 없는 어려움이 존재한다. 그림 1은 기본 이동 경로에서 발생할 수 있는 편차들을 보여주며, 원은 센서노드들을, 채워진 원은 활성화된 센서노드들 그리고 테두리가 있는 원은 사용자가 움직인 실제 경로는 나타낸다.




그림 1. 사용자의 기본 이동경로 및 발생 가능한 편차
Fig 1. Sensor activations as user deviates from his default course of movement.

따라서 본 연구에서는 ADL의 인지를 위한 네트워크의 고차원 모델을 정의하는데 있어 발생 가능한 모든 상황들의 조합을 고려하지 않고 특정 행위에 대해 센서들 간에 시간적으로 연관이 있는 것들에 초점을 맞춘다. 예를 들어 '식사를 준비한다.'라는 행위는 '부엌으로 간다.' 또는 '가스버너를 켜다.'

와 같은 행위들에 연관이 있을 수 있으며, 당연히 사용자가 식사를 준비하는 동안 이와 같은 기기들에 부착된 센서들이 작동하게 되는 것이다. 물론 식사를 준비하는 동안 전혀 상관이 없는 다른 센서들이 작동할 수도 있지만, 가장 관련이 있는 센서들을 찾아내고 인지하고자 하는 행위와 상관없는 센서들을 걸러내는 것이 사용자 행위 인지의 성능을 높일 수 있다.

기존의 행위 인지 시스템은 중앙집중식 처리 방식을 가지며, 센서 데이터들은 중앙 서버로 수집된 후에 일괄적인 추론 과정을 거쳐 행위들을 인지해낸다[1,2,4]. 이는 통신과 처리에 대한 부하가 중앙 서버로 집중되는 단점이 있으나, 네트워크의 공간 복잡도는 불연속 값의 확률 변수의 크기에 따라, 시간 복잡도는 특징을 만들어 내는 추가적인 단계의 증가에 따라 기하급수적으로 늘어난다[5]. 따라서 공간과 시간의 복잡도는 복잡 네트워크 구조(Complex Network Structure)에서는 제어할 수 없게 될 수도 있다[1,6]. 예를 들어 분산으로 처리하지 않는다면, N 개의 상태를 가지는 은닉 마코프 모델(HMM: Hidden Markov Model)은 N^V 개의 상태 변환 확률을 가질 수 있으며 2^N 개의 출력 확률을 그리고 L의 길이를 가지는 출력 수열의 확률을 유도하기 위한 N^2L 개의 시간 복잡도를 가질 수 있다[7]. 그러므로 시간과 공간의 복잡도를 줄이고 연산을 분산화하기 위해서는 효율적인 분산 알고리즘이 요구된다.

본 논문에서는 위와 같은 문제점들의 해결을 위해 무선 센서 네트워크(WSN: Wireless Sensor Network)환경에서 수집된 다양한 센서들의 동작 순서를 기반으로 행위를 인지하는 분산 확률추론 기법을 제안한다. 센서들 간의 순차적인 관계에 기반을 둔 행위 인지가 분산추론을 통해 구현이 가능하며, 이를 위해 각 센서들이 저장하고 있는 확률 데이터를 이용한다. 각 센서들은 그 센서 자신의 확률과 다른 행위 인지를 위한 다른 센서 노드에 대한 조건부 확률을 가진다.

본 알고리즘의 동작은 다음과 같다. 우선 각 센서노드는 동작할 시점에 자신의 상태를 브로드캐스트 하고 다른 센서들은 그 상태정보를 받아 현재 동작하고 있는 센서의 리스트를 생성한다. 그리고 센서들은 샘플링 시간 이후에 새로운 실행 순서를 정한다. 새로운 실행 순서로의 삽입 기회는 최종 샘플링 시간에 동작 신호를 브로드캐스트 한 센서가 가지게 된다. 따라서 각 센서들은 이전 몇 번의 샘플링 시간에 동작 신호를 보낸 센서들의 리스트를 지속적으로 유지하게 되는 것이

다. 이 센서 실행 순서를 가지고 인지해야 할 각 행위에 대한 가상 은닉 마코프 모델(HMM: Hidden Markov Model)을 구축할 수 있게 된다. 각 센서들을 HMM의 상태로 매핑 함으로써 각 센서 자신에 대한 HMM 상태의 계산을 분산화 할 수 있게 된다. 은닉 마코프 모델을 사용한 이유는 그래프로 시각화할 수 있을 뿐 아니라 상태에 대한 시간 순서를 보여줄 수 있기 때문이다.

II. 관련 연구

분산 행위 인지는 아직 생소한 기술로써 2년 전에 처음으로 연구가 이루어졌다[5]. 사용자를 움직임을 추적하는 데이터에서 계층적 특징 추출 개념을 이용하였으며, 핵심 추론 알고리즘으로 시간 특징들을 입력으로 받는 Naïve Bayes를 사용하였다. 반면 본 논문에서는 분산 추론 메커니즘을 사용하였으며 특히 특징 값에 대한 센서 노드에서의 처리와 행위 데이터의 추출에 초점을 맞추었으며, 이는 최초의 행위 인지를 위한 분산 추론 메커니즘이다.

분산 행위 인지 기술의 기반이 되는 분산 컨텍스트 추론 기술을 살펴보면, 기존의 많은 연구들은 센서에서 측정된 값을 중앙의 일부 노드에서 수집하여 처리하는, 중앙 집중식의 추론 방식에 초점이 맞춰져 있었다. 하지만 분산 추론방식으로 데이터를 처리할 경우 각각의 노드에서 병렬적인 처리가 가능하므로 확장 가능한 시스템이나 대규모의 시스템에서 보다 효율적으로 데이터의 처리가 가능하며, 센서 내에서의 전처리 과정을 통해 측정된 모든 데이터를 선별적 혹은 가공 후 전송할 수 있으므로 통신에 드는 비용을 줄일 수 있다. 또한 센서에서 수집한 값에 대한 센서 내에서의 자가 처리를 통해 실시간 어플리케이션과 같이 즉각적인 판단이 요구되는 시스템인 u-라이프케어 또는 응급 상황에 빠르게 대처해야 하는 u-헬스케어 시스템에 적절하다.

실제 환경에 센서들을 배치하고 행위 인지를 시도한 연구는 [1,8]에 처음으로 이루어졌다. 77개의 On/Off센서들을 일반 가정집에 설치하고 일상 행위 데이터를 수집하였으나 최대 27%의 매우 낮은 행위 인지 정확도를 보였다. 센서들 간의 수행 시간들 간의 관계를 기반으로 행위 인지를 시도하였으나 추출하는 특징들이 증가함에 따라 정확도는 감소하는 결과를 보였다. 반면 본 논문에서는 동일한 데이터를 가지고 동일한 방법론을 가지고 실험하였으나 그 정확도가 매우 증가함을 보여주고 있다. 또한 동일한 센서의 배치 환경에서도 ADL들의 인지를 위해 분산 추론이 사용될 수 있음을 보여준다.

이동성 기반의 행위 검출은 행위 인지의 한 분야로써 사용

자의 움직임만을 사용하여 판단한다. 이동성 기반의 행위 인지에 대해, Hierarchical HMM[4], Bayes Filter[2], Dynamic Bayesian Network[9], Naïve Bayes[5]와 같은 다양한 연구들이 선행되었다. [5]의 연구를 제외한 다른 모든 연구들은 중앙 집중식 데이터 처리방식과 특정 도메인에 대한 측정 기술만을 사용하는 제약이 있다. 반면 본 논문에서는 범용 분산 모델을 제시하고 실제 도메인에 적용을 위해 어떠한 방식으로 접근하여야 하는지에 대한 예를 제시한다. 위의 연구들에서는 동일한 네트워크에서 여러 시간에 걸쳐 생성된 데이터를 한 번에 처리하는 구조로써, 만약 제대로 설계가 되지 못한다면 막대한 처리 비용이 요구되며 결국 시스템 전체에 대한 제약이 어려워질 수 있다[1,6]. 반면 본 논문에서 제안하는 알고리즘은 제안한 모델에 따라 시간 흐름에 따라 즉시 처리되는 구조로써 이와 같은 문제점을 해결하였다.

본 논문에서는 HMM을 구성하고 ADL들을 인지하기 위한 센서 네트워크에 적용한 그래프 모델을 제안한다. 각각의 센서들은 작은 크기의 확률 정보들만을 관리하고 다른 센서들과 통신을 통해 공유하여 사용자 행위를 인지하고 판단하는 역할을 한다.

III. 무선 센서 네트워크에서의 확률 추론

중앙 집중식의 처리에 비해 분산 처리방식은 노드간의 비동기화된 통신으로 인해 확률 추론에 대한 통일성을 보장하기 어려우며, 동적으로 변화하는 무선 센서 네트워크의 네트워크 구성과 네트워크의 에러와 충돌 등으로 인한 신뢰성을 보장하기 힘들다. 또한 배터리의 수명과 컴퓨팅 및 통신 자원이 매우 제약적이므로 이와 같은 많은 문제점을 가지고 있다. 최근에는 중앙 집중방식의 구조를 퓨전 센터(Fusion Center)를 가지는 분산 추론구조로 수정하려는 연구가 진행되고 있다. 클러스터링 기법은 주위 노드들을 그룹화한 후 클러스터 헤드(CH)가 데이터를 수집하여 필터링을 한 후 가공된 데이터를 퓨전 센터로 보내는 방식으로, 가공 데이터는 지역적인 학습 룰이나 데이터 등과 같이 특정 정보를 포함한다.

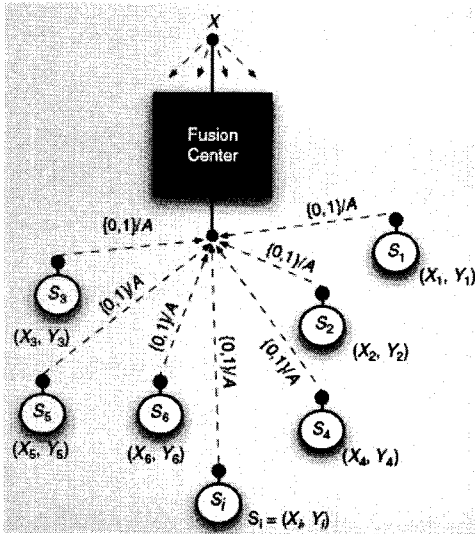


그림 2. 분산 추론을 위한 노드 구성
Fig 2. Node configuration for distributed inference

그림 2와 같은 방식은 중앙의 퓨전 센터로 각각의 노드들이 로컬 영역의 0/1 또는 획득 데이터를 전송하는 구조를 나타낸다. 하지만 이 같은 방식은 클러스터 헤드나 퓨전 센터가 오류가 났을 경우 전체 추론 시스템이 재구성되어야 한다는 단점이 존재한다. 그러나 메시지 전달 알고리즘은 퓨전 센터와 같은 단일 포인트가 없고 각 노드들 간의 데이터의 전달을 통해 추론을 해나가는 장식으로, 일부 노드의 오류로 인해 전체 시스템이 영향을 받지 않으며 통신이 간단해지고 확장성이 있으며 제약된 시스템 자원으로 효율적인 활용이 가능하다.

확률 추론은 부분에 국한되거나 잡음 정보를 추론해내기 위해 쓰이는 강력한 도구로써, 센서 네트워크에서는 센서가 불완전한 환경정보를 측정했을 경우 유용하게 쓰일 수 있다. 일반적인 용도는 환경에 대한 확률 모델과 측정값들이 주어졌을 경우 얻고자 하는 값의 사후 분포를 계산하는데 쓰이며, 본 연구에서는 N개의 센서들을 포함하는 행위 인지 어플리케이션에 이 이론을 사용할 것이다. 각각의 노드 i 가 3개의 관련 변수들인 측정값인 M_i , 해당 센서 위치의 값인 T_i 그리고 센서의 바이어스 값인 B_i 를 가지고 있는 경우 확률 모델을 적용하기에 적절하다. 이 확률 모델은 다양한 위치에서의 센서 값들 간의 상관관계를 나타내는 Prior 모델과 실 측정값과 센서 바이어스가 주어진 센서 측정값들의 가능성을 가진 각각 노드들의 센서 모델인 두 개의 모델로 나뉜다. Prior는 센서 값들 사이의 직접 혹은 간접적인 상관관계를 간단히 표현하는 Markov network라 불리는 구조 모델이며, 완전한 Joint PMF(Probability Mass Function)은 다음과 같이 주어진다.

$$\Pr\{T_1, \dots, T_N, B_1, \dots, B_N, M_1, \dots, M_N\} \propto \prod_{(i,j) \in \mathcal{E}} \psi_{ij}(T_i, T_j) \prod_{n=1}^N \Pr\{B_n\} \Pr\{M_n | B_n, T_n\} \dots \dots \dots \text{(식 1)}$$

여기서 $\psi_{ij}(T_i, T_j)$ 는 값의 Prior를 정의하는 Markov Network의 일부이고 Markov Network의 Edge당 하나의 Factor가 존재하며 이전의 관찰 값으로 학습된다. 만약 $\overline{m_{1:N}} = (\overline{m_1}, \dots, \overline{m_N})$ 의 센서 측정값을 얻었다고 가정할 경우, 이 값들을 Joint Density Function에 대입하고 T_i 로부터 기대되는 모든 변수들을 무시할 경우 다음과 같은 측정값을 가진 T_i 의 사후 분포를 얻을 수 있다.

$$\Pr\{t_i | \overline{m_{1:N}}\} \propto \sum_{b_{1:N}} \sum_{t_N} \Pr\{t_i, b_{1:N}, \overline{m_{1:N}}\} \dots \dots \text{(식 2)}$$

T_i 의 사후 확률 분포는 모든 센서 바이어스와 잡음들로부터 필터링된 센서 측정값을 이용한 노드 i 의 온도를 예측하는데 쓰이며, 센서 네트워크가 보다 밀집되어감에 따라 보다 변수들 간의 상관관계가 보다 강력해질 것이며 바이어스들의 보다 큰 조각들이 자동으로 제거될 것이다.

수식 (1)에서와 같이 네트워크상의 모든 변수를 포함하는 전역 함수로써 Joint PMF를 고려하였다. Factor Graph는 전역 함수를 작고 간단한 로컬 함수로 나누고 메시지 전달 알고리즘을 적용하여 계산하며 분산 프로퍼티들을 활용하여 처리의 복잡도를 낮추는 방법으로 Function-Marginalization을 발견하는 훌륭한 도구이다. 대부분의 경우 분산 추론을 위한 그래프 모델은 Loop들을 포함하므로 정확하고 높은 결과를 얻기 위해서는 메시지 전달 알고리즘의 사용해야 하며 Junction Tree, Loopy BP 또는 Loop Correction과 같은 알고리즘들 [15]이 있다. 그림 3은 무선 센서네트워크의 센서 노드들이 본 연구에서 제안한 분산 추론(DISTIN : DISTributed INFERENCE) 기능을 도입한 시스템으로, 확률 추론에 쓰이는 메시지 전달 알고리즘과 그래프 기반의 모델을 기반으로 각 세부모듈들이 구성되어 있다.

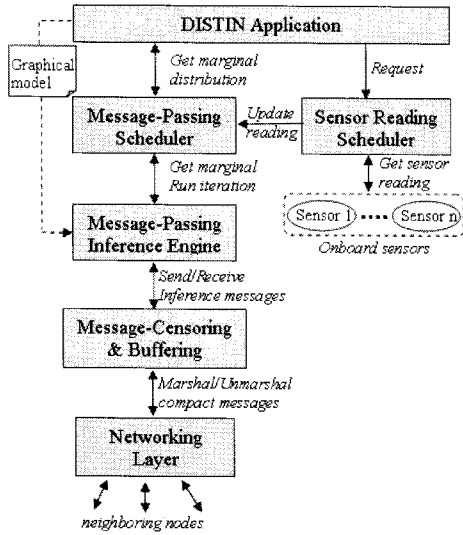


그림 3. 분산 추론을 위한 각 센서노드들의 시스템 구조
Fig 3. System architecture of each sensor nodes for distributed inference

IV. 재구성 가능한 분산 행위 인지 알고리즘

무선 센서 네트워크 환경에서 센서들은 자신들의 상태나 수집한 데이터들을 브로드캐스트하고, 속해있는 클러스터 헤더나 혹은 통신 범위에 있는 모든 센서들에게 전달된다[11]. 각 센서들은 로컬 데이터를 주변 센서 노드들로부터 데이터를 받게 되며 그 데이터에 대한 처리를 각 센서 내에서 하게 된다. 이에 착안하여 본 논문에서는 각 행위에 대한 처리를 위해 은닉 마코프 모델과 같은 구조의 도움을 받아 로컬 데이터를 처리할 수 있는 매커니즘을 제안한다. ADLs를 인지하기 위한 센서 값들 간의 시간 관계를 얻어오기 위하여 HMM을 사용하며 이를 재구성 가능한(Reconfigurable) HMM이라 정의하고 이를 다음 장에서 설명한다.

4.1 재구성 가능한 HMM

은닉 마코프 모델(HMM)은 내부 연결 관계를 가지는 각 상태들 간의 집합으로 정의되며, 사전 확률인 상태에 대한 출력 확률 그리고 상태 전이 확률(State Transition Probability)들을 정의한다. 본 논문에서는 각 센서들이 HMM내의 하나의 상태들로 간주되며 각각의 행위에 대해 자기 다른 HMM을 정의한다. 따라서 HMM내의 각 상태에 대한 사전 확률은 특정

행위 중에 동작하는 센서에 대한 사전 확률이라 할 수 있다. 또한 상태 전이 확률은 다른 어떠한 센서가 동작하기 이전에 동작하는 센서의 조건부 확률이다.

센서들은 사용자가 어떠한 행위를 하는 중에 동작되거나 동작이 정지된다. 센서의 동작을 주기적으로 살펴보면 센서들의 동작에 대한 순서를 얻을 수 있다. 이 동작의 순서를 통해 사용자가 어떠한 행동을 하는 지를 알아낼 수 있으며 이러한 순서 정보를 기반으로 센서 동작을 포함하는 가상 HMM를 구축할 수 있다. 가상 HMM을 구축한 후에는 각 행위에 대한 HMM을 분석하고 높은 연관을 가지는 행위가 발생된 정보를 기반으로 각 행위에 대한 가능성을 계산해낼 수 있다. 발생 가능한 수많은 상황에 대한 필터링을 위해, 현재의 행위가 이전의 추론을 통해 얻은 행위와 일치하는 경우에만 고려한다. 또한 HMM은 센서들의 이전 특정 시간동안의 네트워크 변화에 따라 재구성이 가능하다.

표 1. 제안 알고리즘에서 사용된 용어 정의
Table 1. Terms definition for proposed algorithm

$P_a(S_i)$	= Prior probability of sensor i for activity 'a'
$P_a(S_j S_i)$	= Conditional probability of S_j given S_i for activity 'a'
$P_a(O_{0i})$	= Probability of output O_0 from sensor i for activity 'a'
S_i^t	= HMM state constructed with sensor i, time t
$P_a(S_i^t)$	= Calculated probability (usually maximum likelihood) of S_i^t for activity 'a'
$P_a(S_j^t S_i^{t-1})$	= State transition probability of S_j^t given S_i^{t-1}




그림 4. 어떤 행위에 대한 마지막 3개의 시간 순서 HMM
Fig 4. HMM constructed with the sensors in the last three time sequences for any particular activity.

위 그림 4에서 시간 (t-1)의 상자와 원, 그리고 화살표로 표시된 모든 상태들은 시간 t의 모든 센서들과 연결되어 있음을 뜻한다.

4.2 최대 확률 값 계산 알고리즘

각 행위에 대해 HMM이 구축된 후에는 표준 메시지 전달 알고리즘과 비슷한 최대 가능성(Maximum Likelihood) 알고리즘(10,12) 을 이용하여 각 HMM에 대한 확률 값을 구한다. 또한 제안하는 알고리즘은 몇몇 연산을 max 연산으로 치환한 HMM의 Forward 알고리즘(13)의 개념을 사용한다. 각 상태는 아래와 같은 수식을 통해 최대 확률 값을 계산해낼 수 있다.

$$P_a(S_i^t) = P_a(S_i)P_a(O_{0i}), \quad i = \text{마지막 순서} \dots \text{(식 3)}$$

$$P_a(S_i^t) = P_a(O_{0i})\max[P_a(S_i^t|S_c^{t-1})P_a(S_c^{t-1})],$$

그 외 (식 4)

4.3 BP(Belief Propagation) 알고리즘의 복잡도

만약 길이 T의 센서 순서의 행위에 대한 확률 값을 계산하려고 한다면, 마지막 T시간 동안에 동작된 모든 센서들의 정보를 알아야 한다. 먼저 마지막 T시간 동안에 동작한 센서들은 자신의 확률을 수식 (3)을 사용하여 계산한 후 이를 브로드캐스트한다. 마지막 (T-1)시간 동안에 동작한 센서들은 자신의 확률을 계산하기 위해 브로드캐스트된 확률을 수식(4)을 사용하여 계산한다. 이 같은 계산과정은 현재 동작하고 있는 센서가 자신의 확률을 계산할 때 까지 계속된다. 그리하여 마지막 T 시간 이내에 이전 동작 센서들이 총 (T-1)번의 메시지 전달 후에, 현재 동작 센서는 T 순서에 대한 확률을 얻게 된다. 각 행위에 대한 각 센서의 시간 복잡도는 각 센서의 통신 범위 내에 동작 센서들을 포함하는 선형 구조를 가지며, 통신 오버헤드는 길이 T의 순서이고 공간 복잡도는 센서들에 분산되며, 최악의 경우 각 센서는 다른 모든 센서들의 조건부 확률만을 갖게 된다.

통신 오버헤드 같은 보내어질 메시지들의 개수는 최적화 될 수 있으며 그 수를 반으로 줄일 수도 있다. 이는 T 시간동안 확률을 계산하면서 동시에 이전 순서에 있는 센서들의 확률을 동시에 계산하여 같은 메시지에 넣어 한 번에 보내는 것이다. 이 방법의 선행조건으로는 지난 i 번째 시간 순서에 동작한 센서는 i+1 번째까지의 확률을 보내야 하며, T-i+1 길

이의 순서에 대한 확률 또한 보내야 한다. 이 계산은 통신 오버헤드를 반으로 줄일 수 있으나 계산 복잡도는 동일하다.

V. 성능평가 및 분석

본 논문의 성능평가를 위하여 MIT Place Lab(1,14)에서 제공하는 공개 데이터를 사용하였다. 77개의 on/off 센서들을 한 명이 거주하는 공간에 배치하였으며 중앙 서버에서 데이터를 수집하고 Experience Sampling Method(ESM)[1]을 사용하여 레이블링 하였다. 특징들 간의 시간 관계가 필요한 경우 분류(Classification) 문제 해결에 있어서 본 논문에서 제시하는 모델이 더 효율적임을 보여주기 위해 이 데이터를 사용하였다.

성능평가를 위해 모든 센서들이 통신 범위 안에 있고 다른 모든 센서들로부터 브로드캐스트를 받을 수 있다고 가정한다. 또한 모든 센서들은 시간 동기화가 되어 있으며 동일한 시간 간격으로 센서의 상태 정보를 브로드캐스트하고 수신한다고 가정한다. ADL 인지 정확도의 개선을 보여주기 위해 위와 같은 이상적인 환경을 가정하였다. 성능평가의 입력 데이터는 [14]의 텍스트 데이터를 사용하였으며 매 5초마다 센서 데이터를 수집하고, 한 스프레드가 하나의 센서를 나타내는 다중 스프레드 구조의 시뮬레이터로 전달하는 구조를 가진다. 스프레드들은 서로 통신하며 한 번의 동기화된 메시지 전달 후에 각 스프레드는 한 행위의 전체 또는 최대 확률을 계산할 수 있다. 이 계산된 확률은 클러스터 헤드 역할을 하는 프로그램으로 전달 되어 확률의 총 합이나 전역 최대 확률을 계산해낸다.

시뮬레이션 프로그램은 두 단계로 동작한다. Frequency Counting을 통해 센서의 사전 확률과 조건부 확률을 구한 후, 센서 데이터의 순서를 알아내고 수식 1의 알고리즘을 이용하여 행위를 인지해낸다. 센서들이 전부 on/off센서이므로 센서가 on 상태일 때만 데이터를 수집한다. 따라서 동작 상태에서의 출력 값은 on값뿐이며 이 상태일 때 확률은 센서 노드의 사전확률과 같다. 사전확률(Prior Probability)은 $P_a(O_{0i}) = P_a(ON_i) = P_a(S_i)$ 이며, 수식 1의 $P_a(O_{0i})$ 는 $P_a(S_i)$ 로 바뀐다.

본 성능평가를 통해 순서 길이를 늘이면 인지의 정확성 또한 일정 수준까지는 높아지는 것을 알 수 있었다. 수식 1에서와 같이 최대 확률 BP알고리즘을 사용하여 평균 인지 정확도를 표 1과 같이 얻어낼 수 있었으며 5개의 순서 길이가 최적을 결과를 내었다. 알고리즘을 사용하여 매 1초와 30초마다 센서 데이터를 수집하여 평균 정확도를 구했으며 길이가 5일

때 47%의 정확도를, 4일 때 53%의 정확도를 나타내었다. 따라서 [14]의 환경에서 ADL을 인지하기 위해 본 논문에서 제안하는 알고리즘을 사용할 경우, 순서 길이는 5로 해야 함을 알 수 있었으며, 전달되는 메시지는 3개로, 계산은 센서 당 5개로 하는 것이 적절하며, 이는 실제 실시간 시스템에서 사용하기에 적합하다.

표 2. 최대 확률 알고리즘을 이용하여 계산한 평균 인지 정확도
Table 2. Average recognition accuracy using maximum likelihood algorithm

순서길이	2	3	4	5	6	7	8
정확도	40	48	52	54	51	48	45

표 3은 [14]에서 주어진 모든 행위들에 대한 평균 정확도 결과표로써 순서 길이는 5로 센서 값은 매 5초마다 샘플링 하여 얻은 결과이다.

표 3. 제안하는 알고리즘의 행위 인지 정확도
Table 3. Activity wise recognition accuracy of the proposed algorithm

행위	샘플갯수	정확도
Bathing	213	69.95
Toileting	232	56.03
Going out to work	1	100.0
Preparing lunch	362	35.63
Preparing dinner	98	31.63
Preparing breakfast	58	44.96
Dressing	129	69.76
Grooming	260	58.07
Preparing a snack	63	58.73
Preparing a beverage	60	70.0
Washing dishes	60	76.66
Doing laundry	150	61.33
Cleaning	140	18.57
Putting away dishes	48	81.25
Washing hands	4	100.0
Putting away groceries	31	74.19
Other	16	93.75
Watching TV	35	48.57
Going out for entertainment	5	80
Lawnwork	39	97.43
Putting away laundry	2	0
Average Accuracy		54.02%

표 3은 순서길이 5, 샘플링 주기 5초로 측정된 행위의 정확도이며, 평균 정확도인 54%는 작은 Training Set과 잡음 때문에 일어난 결과로써 이 또한 [1]에서 언급되어 있다. ADL의 인지에 있어 각기 개별적인 행위들을 하나의 공통된 행위로 묶어서 인지하는 것이 정확도를 높일 수 있으므로, 여

러 행위들을 통합한 'meal preparation'을 고려하여 다시 실험한 결과는 다음 표 4와 같다.

표 4. 여러 행위들을 하나로 처리한 경우 행위 인지 정확도
Table 4. Activity recognition accuracy when multiple activities are treated as a single one

행위	정확도
Bathing	71.04
Toileting	56.47
Going out to work	25.0
Meal Preparation(Preparing lunch, Preparing dinner, Preparing breakfast, Cleaning, Washing dishes, Preparing a snack, Putting away dishes, Putting away groceries)	65.21
Dressing	72.44
Grooming	59.02
Preparing a beverage	75.0
Doing laundry	62.0
Washing hands	100.0
Other	88.23
Watching TV	60.86
Going out for entertainment	80.0
Lawnwork	97.43
Putting away laundry	0
Average Accuracy	65.16%

또한 본 성능평가의 결과를 MIT의 결과[1]와 비교해 보았다. 본 논문의 알고리즘은 73.47%의 정확도를 보였으며 MIT의 최대 정확도는 27%였다. 만약 행위의 종류를 제한하고 많은 샘플을 얻거나 인지 범위를 제한한다면 보다 높은 정확도를 가진 결과를 얻을 수 있을 것이다.

표 5. 동일한 행위에 대한 MIT의 결과와의 비교
Table 5. Comparison of our result with MIT on the same set of activities

행위	MIT결과	본 논문의 결과
Preparing lunch	25	74.52
Toileting	27	62.77
Preparing breakfast	8	67.87
Bathing	25	63.20
Dressing	7	85.18
Grooming	26	77.63
Preparing a beverage	7	87.14
Doing laundry	9	84.04
Average Accuracy	16.75	75.29 (449.5% 정확도향상)

VI. 제안하는 알고리즘의 응용

본 논문에서 제시한 분산 행위 인지 알고리즘은 사용자의 행위나 의도를 정확하고 신속하게 파악하여 빠른 응답(서비스)을 제공해야 하는 u-라이프케어 응용의 핵심 요소 기술로 활용될 수 있다. 특히 낙상 감지(Fall Detection) 어플리케이션의 경우 낙상은 노약자나 장애인들에게는 치명적인 결과를 가져올 수 있고 신속한 응급 서비스가 제공되어야 한다는 점에서 많은 연구들이 수행되고 있다. 게다가 실제로 관련 연구 뿐 아니라 이를 활용한 상용 제품이 출시되어 있으며 정확성을 높이기 위해 많은 노력들이 이루어지고 있다.

반면, 건강한 일반인들에게도 행위 인지 기술은 많은 도움을 가져다준다. 현대인의 가장 심각한 질병으로 인식되고 있는 우울증이나 당뇨와 같은 질병은 간단한 검사나 테스트로 발견될 수 있는 것이 아닌 '장기적인' 행위패턴 모니터링과 분석을 통해 검출이 가능하다. 따라서 본 행위 인지 알고리즘을 적용한 소형기기를 사용자가 몸에 지니고 주기적으로 행위 정보를 제공한다면, 사용자의 일상생활 행위 패턴이나 습관들을 시스템이 분석하여 질병 가능성이 있는 질병을 조기에 검출하고 대응할 수 있다.

마지막으로 행위 인지가 널리 쓰이는 분야로는 u-라이프케어 외에도 엔터테인먼트 분야를 꼽을 수 있다. 기존의 Wii[16]와 같은 대표적인 행위 인지 기술을 적용한 게임 콘솔의 경우 각속도와 가속도계를 사용하여 사용자의 특정 행위(손을 흔들거나 몸의 무게중심을 이동)를 검출하여 이를 엔터테인먼트 콘텐츠와 접목시켜 큰 반향을 불러일으켰다. 이 기기의 경우에도 소형 디바이스 콘솔과 본체와의 통신 그리고 사용자가 주변의 각종 기기들이 협력하여 서비스를 제공하는 방식으로, 본 연구에서 제안하는 분산추론을 활용한 행위 인지 기술이 사용될 수 있다. 단지 손이나 발의 움직임 뿐 아니라 걷기, 뛰기, 달리기 또는 비틀기 등 사용자의 다양한 행위를 엔터테인먼트 콘텐츠의 입력을 활용한다면 보다 실감나고 게임에 몰입을 제공할 수 있는 기술이 될 것이다.

VII. 결론 및 향후 연구

본 논문에서는 일상생활 행위의 인지를 위한 분산 확률 모델을 제안하였으며, 일반 가정 규모의 환경에서 수집된 데이터를 이용하여 정확도를 제시하였다. 제안하는 모델은 주어진 데이터를 기반으로 행위들을 완벽하게 인지하였으나, 실제 레

이블된 데이터를 얻는 것은 매우 비용이 많이 들며 많은 연구들이 진행되고 있다. 향후 연구로는 이론상으로 제시하고 시뮬레이션을 통해 검증받은 본 알고리즘을 실제 가정환경에서 수집된 데이터들을 이용하여 적용해 볼 것이다. 특히 u-라이프케어 분야에 적용하여 이를 통해 실제 환경에서 일어나는 예기치 못한 상황들(노이즈, 지연, 오작동 등)로 인한 결과를 바탕으로 본 알고리즘을 보다 개선해 나갈 것이다.

참고문헌

- [1] E. Tapia, S. Intille, and K. Larson, "Activity Recognition in the home setting using simple and ubiquitous sensors", Proceedings of PERVASIVE 2004, Vol. LNCS 3001, pp. 158-175, Apr. 2004.
- [2] Donald J. Patterson, Lin Liao, Dieter Fox, and Henry Kautz, "Inferring High-Level Behavior from Low-Level Sensors", Ubicomp, Oct. 2003.
- [3] S. S. Intille, K. Larson, E. Munguia Tapia, J. Beaudin, P. Kaushik, J. Nawyn, and R. Rockinson, "Using a live-in laboratory for ubiquitous computing research", In Proceedings of PERVASIVE 2006, vol. LNCS 3968, pp. 349-365, May 2006.
- [4] Sebastian Lühr, Hung H. Bui, Svetha Venkatesh, Geoff A. W. West, "Recognition of Human Activity through Hierarchical Stochastic Learning", First IEEE International Conference on Pervasive Computing and Communications (PerCom'03), Mar. 2003.
- [5] Christopher R. Wren and Emmanuel Munguia Tapia, "Toward Scalable Activity Recognition for Sensor Networks", In Proceedings of The Second International Workshop in Location and Context-Awareness (LoCA '06), Springer vol. 3987, pp. 168-185, May 2006.
- [6] Sangho Park, Jake K. Aggarwal, "A hierarchical Bayesian network for event recognition of human actions and interactions", Multimedia Syst. Vol. 10, No. 2, pp. 164-179, Oct. 2004.
- [7] 이지근, 김명훈, 이상설, 정성태, "HMM(Hidden Markov Model) 기반의 견고한 실시간 리리딩을 위한 효율적인 VLSI 구조 설계 및 FPGA 구현을 이용한 검증", 한국컴퓨터정보학회논문지, 제 11권, 2호, 159-167쪽, 2006년 5월.

- [8] E. Munguia Tapia, "Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors", M.S. Thesis Media Arts and Sciences, Massachusetts Institute of Technology, September 2003.
- [9] 차병래, 박경우, 서재현, "이상 침입 탐지를 위한 베이지안 네트워크 기반의 정상행위 프로파일링", 한국컴퓨터정보학회논문지, 제 8권, 제1호, 103-113쪽, 2003년 3월.
- [10] Alexander T. Ihler, "Inference in Sensor Networks: Graphical Models and Particle Methods", Ph. D Thesis, MIT, June 2005.
- [11] Xiao Renyi, Wu Guozheng, "A Survey on Routing in Wireless Sensor Networks", Progress in Natural Science, Vol. 17, No. 3, pp. 261 - 269, Mar. 2007.
- [12] Christopher M. Bishop, "Chapter 8: Graphical Models, Pattern Recognition and Machine Learning", Springer 2006.
- [13] Rabiner L. R., Juang B. H, "An introduction to hidden Markov models", IEEE ASSP Magazine: 4-15, Jan. 1986.
- [14] MIT Activity Recognition data, <http://courses.media.mit.edu/2004fall/mas622j/04.projects/home/>
- [15] Kevin Patrick Murphy, "Dynamic Bayesian Networks: Representation, Inference and Learning", Doctoral Thesis, University of California, Berkeley, 2002.
- [16] Wii, <http://en.wikipedia.org/wiki/Wii>

저자 소개



김홍섭

2008년 2월 : 동국대학교 컴퓨터공학과 공학박사

1994년 ~ 2009년 현재 : 오산대학교 멀티미디어정보과 부교수

관심분야 : 분산운영체제, 임베디드시스템, 유비쿼터스 컴퓨팅



임거수

2004년 2월 : 서강대학교 물리학과 이학박사

2004년 ~ 2009년 현재 : 배재대학교 과학기술학부 전임강사

관심분야 : 신호처리, 비선형 시계열 분석, 네트워크