

베이지안 네트워크에 기반한 스마트 홈에서의 상황인식 기법개발

Context-aware application for smart home based on Bayesian network

정우용* · 김은태*

Woo-Yong Chung and Eun-Tai Kim

* 연세대학교 전기전자공학과

요 약

본 논문은 스마트 홈에서 베이지안 네트워크에 기반을 둔 보편성을 가지는 상황인식 시스템의 구현방법을 제안한다. 베이지안 네트워크는 각 센서정보를 바탕으로 거주자의 활동 및 스마트 홈의 상황에 대한 추론을 확률적으로 접근하는데 매우 유용한 수단이다. 하지만 센서 정보와 활동정보가 다양해짐에 따라 기존의 방법으로는 베이지안 네트워크를 구성하기가 힘들다. 따라서 본 논문에서는 상호정보를 통하여 보다 효율적으로 베이지안 네트워크를 구성하도록 하며, 시뮬레이션을 통하여 자료 취득하고 그에 따른 거주자의 활동인식의 결과를 보인다.

키워드 : 스마트 홈, 센서네트워크, 베이지안 네트워크, 상호정보, 상황인식

Abstract

This paper deals with a context-aware application based on Bayesian network in the smart home. Bayesian network is a powerful graphical tool for learning casual dependencies between various context events and obtaining probability distributions. So we can recognize the resident's activities and home environment based on it. However as the sensors become various, learning the structure become difficult. We construct Bayesian network simple and efficient way with mutual information and evaluated the method in the virtual smart home.

Key Words : Smart home, Sensor network, Bayesian network, Mutual information, Context-awareness

1. 서 론

최근 컴퓨팅 디바이스와 무선 네트워크 기술의 발전은 우리가 주변으로부터 다양한 정보를 보다 쉽게 제공받을 수 있는 환경을 제공하였다. 이러한 정보들은 다양한 사물들이 상황정보를 인식하고 판단하여 우리에게 보다 능동적이고 유용한 서비스를 제공할 수 있는 기반이 된다.

일반적으로 상황정보는 사용자가 상호작용을 하는 시점에서 가용한 거의 모든 정보라고 할 수 있다. 또한, 상황정보는 응용 운용 환경의 일부로 사물이 감지할 수 있는 정보를 가지는데, 일반적으로 사람, 그룹, 객체의 위치, 식별, 활동, 상태 등을 포함한다[1]. 상황인식 서비스는 이러한 상황정보의 수집 및 교환을 통해 상황을 인식하고, 해석 및 추론과 같은 처리 과정을 거쳐 사용자에게 이에 관련된 정보나 서비스를 제공한다.

이 외에도 상황인식 컴퓨팅은 1994년 Schilit와 Theimer에 의하여 논의되었으며, 그 당시 상황인식 컴퓨팅

(context-aware computing)을 '사용 장소, 주변 사람과 물체의 집합에 따라 적응적이며, 동시에 시간이 경과되면서 이러한 대상의 변화까지 수용할 수 있는 소프트웨어'로 정의하였다[2]. 그리고 이후의 지나친 특정적인 정의를 제외하고 가장 개선된 상황인식은 '사용자의 작업과 관련 있는 적절한 정보 또는 서비스를 사용자에게 제공하는 과정에서 상황을 사용하는 경우 이를 상황인식 시스템'으로 정의할 수 있다.

하지만 현재 제공되는 상황정보에 기반한 서비스는 대부분이 사용자 또는 개발자가 직접 명시한 사항에 대해서만 가능하다. 따라서 보다 보편적으로 상황인식 서비스를 제공할 수 있는 기반이 필요하다고 할 수 있다. 이에 본 논문에서는 스마트 홈에서 베이지안 네트워크에 기반을 둔 보편성을 가지는 상황인식 시스템을 제안한다.

제안된 시스템의 기본이 되는 베이지안 네트워크는 많은 변수들 간의 확률관계를 비교적 축약된 형태로 표현하는데 유용한 모델로 확률적 추론, 예측, 의사 결정 등에 적합한 모델이다. 이러한 특성으로 확률적 성격이 강한 상황인식 연구분야에서 베이지안 네트워크가 사용되고 있다[3][4]. 본 논문에서는 스마트 홈에서 베이지안 네트워크를 보다 쉽게 구성할 수 있도록 상호정보를 사용한 방법을 제안한다.

논문의 구성은 다음과 같은 순서로 구성되어 있다. 제2장에서는 본 논문의 기본이 되는 베이지안 네트워크 및 상호정보에 관하여 간략히 기술한다. 제3장에서는 상황인식 시스템의 베이지안 네트워크를 구성하는 과정에서 상호정보

접수일자 : 2006년 10월 21일

완료일자 : 2007년 1월 31일

감사의 글 : 본 연구는 산업자원부 성장동력기술개발사업 (차세대 Hybrid Intelligent Service Station 기술개발) 프로젝트에 의해 일부 지원 받았습니다.

(mutual information)를 이용한 방법을 소개하고, 제4장에서는 제안된 방법을 통한 시뮬레이션 결과를 통하여 유효성에 관하여 기술한다. 마지막으로 제5장에서는 결론으로 마무리한다.

2. 관련연구

2장에서는 본 논문의 기초가 되는 관련연구로서 베이저안 네트워크의 구조학습과 엔트로피(entropy) 및 상호정보에 대하여 기술한다.

2.1 베이저안 네트워크

베이저안 네트워크는 그래프 모델 중에서 방향성 비순환 그래프(Directed Acyclic Graph, DAG)에 기반을 둔 확률적 모델이다[5]. 방향성 비순환 그래프 모델에서 각 노드를 연결하는 아크는 직접적인 인과 관계를 나타내는 것으로 생각할 수 있기 때문에 때로는 베이저안 네트워크를 인과 네트워크라고 부르기도 한다. 방향성 비순환 그래프는 크게 유한개의 노드들의 집합(V)과 노드 간을 연결하는 경로(E)로 나누어진다.

이 방향성 비순환 그래프의 각 노드는 확률변수를 나타내며, 조건부 확률표가 존재한다. 또한 각 노드 V_i 는 이 노드의 부모 π_i 가 주어지고 π_i 의 후손이 아닌 노드들과 조건부 독립이 된다고 할 때 Markov 조건이 성립된다. 때로는 베이저안 네트워크에서 조건부 독립이 드러날 수 있도록 원인과 결과를 연관시킬 수 있는 경우가 있는데, 이처럼 인과 관계에 대한 직관적인 개념으로 베이저안 네트워크를 구성하면 내재된 조건부 독립 가정에 적합한 네트워크가 된다. 이와 같은 성질을 통해서 그림 1과 같은 베이저안 네트워크의 예는 다음과 같이 식 (1)로 표현된다.




그림 1. 베이저안 네트워크 구조 예
Fig. 1. an example of Bayesian network

$$P(A, B, C, D, E, F, G) = P(A)P(B)P(C)P(D|A, B)P(E|B, C)P(F|D)P(G|E) \quad (1)$$

이와 같이 V_1, V_2, \dots, V_k 를 베이저안 네트워크를 이루고 있는 노드라고 할 때, 이 네트워크가 조건부 독립이라는 가정 하에 이 네트워크의 모든 노드에 대한 결합 확률을 일반화하면 식 (2)와 같이 주어진다.

$$P(V_1, V_2, \dots, V_n) = \prod_{i=1}^n P(V_i | \pi_i) \quad (2)$$

여기서 π_i 는 그래프에서 V_i 의 부모집합이다. 식 (2)는 베이저안 네트워크가 의미하는 부분 순서와 일관성을 유지하는 연쇄 법칙 순서를 사용하는 모든 변수의 결합 확률을 구하는 연쇄 법칙에 조건부 독립을 적용함으로써 쉽게 유도할 수 있다.

이와 같이 베이저안 네트워크의 결합 확률을 구하기 위해서는 우선 네트워크의 구조를 추측하여야 한다. 구조의 학습 방법 중에서 가장 간단한 방법은 모든 그래프에서 점수가 가장 높은 것을 찾는 방법(exhaustive search and score decomposability)이다. 여기서 점수를 매기는 방법 S(B)와 n개의 노드로 생성될 수 있는 베이저안 네트워크의 수 r(n)은 식 (3)과 식(4)와 같다.

$$S(B) = \sum_{i=1}^n s(X_i, \pi(X_i)) \text{ or } S(B) = \prod_{i=1}^n s(X_i, \pi(X_i)) \quad (3)$$

$$r(n) = \sum_{i=1}^n (-1)^{i+1} \binom{n}{i} 2^{i(n-1)} r(n-i) = n^{2^{(n)}} \quad (4)$$

위의 식에서 r(n)을 살펴보면 두개의 노드일 때는 3개의 베이저안 네트워크가 존재하지만, 10개의 노드일 때는 4.2×10^{18} 개의 수많은 베이저안 네트워크가 존재하기 때문에 이와 같은 방법은 최대 7개까지 노드를 가지는 경우에만 가능하다.

이 외에도 사례들을 통해서 트리 구조를 추측하거나, 유전자 알고리즘을 사용하는 방법[6] 등의 다양한 구조 학습 알고리즘이 있다. 그 중에서도 가장 많이 사용되는 알고리즘은 K2알고리즘으로 Cooper와 Hersovits에 의해서 제안되었다[7].

2.2 엔트로피 및 상호정보

자기 조직화(self-organizing) 시스템을 구성하는데 가장 중요한 것은 입력과 출력을 바탕으로 입출력 관계를 학습할 수 있는 알고리즘을 개발하는 것이다. 그러한 면에서는 상호정보는 몇 가지의 매우 유용한 특성을 가지고 있기 때문에 가치가 크다고 할 수 있다. 이러한 특성으로 상호정보를 이용하여 베이저안 네트워크를 구성하는 연구도 진행되었다[8]. 이와 같은 상호정보는 엔트로피를 통해서 표현되며, 엔트로피는 상호 배타적이면서 각각이 모두 특정한 발생 확률을 갖는 어떤 유한개의 이벤트 가운데서 임의의 하나의 이벤트가 발생함으로써 전달되는 정보 척도의 평균치다. 엔트로피 $H(U)$ 를 수식으로 정의하면 다음과 같은 식 (4)가 된다.

$$H(U) = -p_1 \log p_1 - \dots - p_N \log p_N \quad (4)$$

앞에서 설명한 엔트로피를 바탕으로 상호 정보는 다음과 같이 입력 X와 출력 Y를 가지는 확률적인 시스템을 통해서 설명될 수 있다[9]. X와 Y는 x, y로 표현되는 이산의 값만을 가진다고 가정하자. 그러면 엔트로피 $H(X)$ 는 X에 대한 불확실성에 대한 측정 기준이 된다. 그리고 출력 Y를 관측한 후에 입력 X에 대한 불확실성을 측정하기 위해 다음 식 (5)와 같은 조건부 엔트로피(conditional entropy)를 정의한다.

$$H(X|Y) = H(X, Y) - H(Y), 0 \leq H(X|Y) \leq H(X) \quad (5)$$

위와 같은 조건부 엔트로피 $H(X|Y)$ 는 시스템의 출력 Y 를 관측한 후에 입력 X 에 대한 불확실성에 대한 정도를 나타낸다. 또한 입력 X 와 출력 Y 에 대한 결합 엔트로피(joint entropy)는 다음과 같이 식 (6)으로 정의된다.

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (6)$$

여기서 $p(x, y)$ 는 이산 랜덤 변수 X, Y 의 결합 확률분포 함수이며, X, Y 는 이것들에 대한 기호이다.

엔트로피 $H(X)$ 는 시스템의 결과를 확인하기 전의 입력의 불확실성을 나타내며, 조건부 엔트로피 $H(X|Y)$ 는 출력을 확인 한 후의 시스템의 불확실성을 나타낸다. 따라서 이 둘의 차이인 $H(X) - H(X|Y)$ 는 출력 Y 를 관측한 후의 입력 X 의 불확실성을 나타내게 된다. 이것을 상호 정보(mutual information)라 부르며 식 (7)과 같이 표현된다.

$$I(X; Y) = H(X) - H(X|Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (7)$$

여기서 $H(X)$ 는 상호 정보의 특별한 경우인 $H(X) = I(X; X)$ 에 해당되며, $H(Y|X)$ 는 조건부 엔트로피이다. $H(Y) - H(Y|X)$ 는 시스템 출력 Y 에 의해 전달된 정보의 종합적 평균에서 시스템의 입력 X 를 미리 알고 있는 상태에서의 시스템 출력 Y 에 대한 종합적인 평균을 나타낸다. $H(Y|X)$ 는 시스템의 입력에 대한 정보를 전달하기 보다는 프로세싱 잡음을 전하는 역할을 한다.

앞의 특징을 그림으로 표현하면 그림 2와 같다. 시스템 입력 X 에 대한 엔트로피는 왼쪽 원이고, 시스템 출력 Y 에 대한 엔트로피는 오른쪽 원이 된다. 그리고 X 와 Y 의 상호정보는 두 원이 겹치는 부분으로 표현된다.




그림 2. 상호정보 $I(X;Y)$ 와 엔트로피 $H(X), H(Y)$
Fig. 2. mutual information $I(X;Y)$ and entropy $H(X), H(Y)$

3. 상황인식 시스템

본 논문의 제안하는 상황인식 시스템은 베이지안 네트워크를 통하여 일정한 학습을 한 후에 센서 정보로부터 거주자의 행동을 파악하는 것이다. 3장에서는 이러한 상황인식 시스템을 구성하기 위해서 베이지안 네트워크를 구성하는 방법과 이를 상황인식에 적용하는 과정에 대하여 설명한다.

3.1 스마트 홈에서의 센서 및 활동종류

입력데이터 중에서 환경데이터는 센서 네트워크를 통하여 얻게 되는 정보들로서 시간, 사람의 위치, 각종 전등, 스마트 가전기기 등으로부터 제공된다. 입력데이터는 주기적으로 센서 네트워크를 통해서 DB에 저장되거나, 특정한 이벤트가 일어났을 때 저장되기도 한다. 한편 활동데이터는 가정에서 사람의 활동에 대한 정보를 나타내는데 가정에서 거주자가 할 수 있는 대부분의 행동을 기록한다. 한편 센서 데이터는 자동으로 저장되는 반면 활동데이터는 사람이 직접 입력해주어야 하는 번거로움이 있다. 이러한 것을 보다 수월하게 만들기 위해 [13]에서는 PDA를 통해 일정시간마다 활동을 입력받을 수 있도록 하였고, 그 외에 놓친 거주자의 활동은 음성이나 영상 녹화를 통해서 찾게 된다. 본 논문의 가상 공간에서 사용될 센서 입력과 활동 입력은 표 1과 표 2와 같다.

표 1. 가상 스마트 홈에서의 사용된 센서 종류
Table 1. Sensors for virtual smart home

구분	스위치	가전기기	기타
센서 종류	전등 스위치 (방, 거실, 부엌, 현관, 복도, 화장실, 창고) fan 스위치	TV, 컴퓨터 오디오, 전화기, 세탁기, 냉장고, 에어컨, 보일러	초인종 싱크대, 변기, 세면대, 창문, 샤워기

표 2. 가상 스마트 홈에서의 사용된 활동 종류
Table 2. Activities for virtual smart home

구분	일상생활	활동	집안일	기타
활동 종류	외출 및 귀가, 취침 및 기상, 식사, 휴식, 세면 및 샤워, 화장실, 환복	TV 시청, 컴퓨터, 음악 감상, 독서	집 청소, 음식 준비, 설거지, 빨래	전화, 공부, 컴퓨터

3.2 상호정보를 통한 구조학습

가정에서 사용되는 여러 종류의 지능형 가전기기를 사용하거나 개발자가 직접 베이지안 네트워크에 적용하기에는 많은 불편함이 따른다. 따라서 베이지안 네트워크의 구조학습의 편의를 위해서 각 센서들이 상호 독립이라 가정하고 수행하였다. 그 결과 그림 3과 같이 베이지안 네트워크를 복잡한 구조가 아닌 단순한 형태의 베이지안 네트워크(naive Bayesian network)을 구성하였다[4].




그림 3. 스마트 홈에서의 나이브 베이지안 네트워크
Fig. 3. naive Bayesian network in the smart home

하지만 센서의 종류가 다양한 환경에서는 이러한 모든 정보를 사용하는 것은 불필요한 연산을 유도하므로 각 활동에 따른 중요한 부분을 추출하여야 한다. 즉, 행동이 나타나는데 중요한 역할을 하는 센서정보들을 추출하여야 하는 것이다.

이와 같은 과정은 스마트 홈에서 거주자의 활동을 관찰하고 그에 따른 센서정보의 자유도를 통하여 구현하였다. 즉, 어떤 활동을 할 때 어떤 센서들이 동작을 하고 그 중에서 가장 많이 영향을 주는 것은 어떤 것인지를 찾아내서 구조를 결정하는 것이다. 거주자의 활동을 관찰하면서 센서의 자유도 정보를 확인하는 것을 식으로 표현하면 다음과 같다.

$$\begin{aligned}
 I(S;A) &= H(S) - H(S|A) \\
 &= H(S) - H(S,A) - H(A) \\
 &= \left[\sum_{s \in S} p(s) \log(s) \right] - \left[\sum_{s \in S} \sum_{a \in A} p(s,a) \log p(s,a) \right] \\
 &\quad - \left[\sum_{a \in A} p(a) \log(a) \right] \\
 &= \sum_{s \in S} \sum_{a \in A} p(s,a) \log \left(\frac{p(s,a)}{p(s)p(a)} \right)
 \end{aligned}
 \tag{3}$$

여기서 $H(S)$, $H(A)$ 는 각각 센서 및 활동의 엔트로피이다. 또한 $p(s,a)$ 는 이산 랜덤 변수 s, a 의 결합 확률분포 함수이며, 상호정보 $I(S;A)$ 는 각 활동과 센서들 간의 상관관계를 나타낸다고 할 수 있다.

본 논문에서는 위와 같은 상호정보 값을 사용하여 일정한 수의 연결을 유지하는 형태로 베이지안 네트워크를 구성하였다. 일반적으로 노드의 수가 많을수록 더욱 정밀한 추론이 가능하지만 학습 샘플의 수가 더 많이 필요하게 될 뿐만 아니라 너무 특정화되는 경향이 있다. 따라서 가능한 노드간의 연결이 최소화하여 그림 4처럼 전체가 연결된 구조로부터 그림 5와 같이 중요한 인과관계를 고려한 형태로 베이지안 네트워크를 효율적으로 구성하였다.




그림 4. 나이브 베이지안 네트워크 (구조 학습전)
Fig. 4. naive Bayesian network (before structure learning)




그림 5. 나이브 베이지안 네트워크 (구조 학습후)
Fig. 5. naive Bayesian network (after structure learning)

학습 후에는 그림 5와 같이 각 활동에 관련된 센서들의 인

과관계가 연결되는 것을 볼 수 있다. 여기서 상위의 1부터 23까지의 노드는 센서 노드이며, 하위의 24부터 44까지는 활동 노드이다. 학습된 구조를 살펴보면 시간 및 위치를 나타내는 1번과 2번 노드는 대부분의 활동을 추론하는데 관여하고 있음을 알 수 있다. 위치와 시간을 제외하고 대부분의 센서 노드는 특정 활동에 관여하는 형태로 구조가 학습된 것을 확인할 수 있다. 이 외에도 특정 센서 노드나 활동 노드는 센서와 활동 노드를 연결하는 아크가 없는 것을 확인할 수 있는데 이것은 학습할 자료를 취득하는 과정에서 사용하지 않은 정보가 있다는 것을 의미한다. 즉, 겨울철에 잘 사용하지 않는 에어컨과 같은 기기들이 이러한 경우를 나타낸다고 할 수 있다.

4. 시뮬레이션 및 결과 고찰

4.1 상황인식 시뮬레이터

사용자에 대한 센서자료와 활동자료는 그림 6과 같은 플래시에 기반을 둔 인터페이스를 만들어서 수집하였다. 수집 과정은 가상의 집에서 거주자가 활동하고, 각 활동에 대한 각종 정보는 데이터베이스에 저장 된다. 이때 센서들은 스위치를 켜게 되면 자동으로 저장되지만, 사용자의 활동정보는 직접 입력해주어야 하며, 선택할 수 있는 활동의 종류는 한 가지가 된다. 그러면 활동들은 각각 할당된 최소시간이 기본적으로 지나게 되며, 그 후에도 같은 행동을 하게 되면 사용자가 임의의 시간을 설정하여 그 내용이 데이터베이스에 저장될 수 있도록 한다.




그림 6. 상황인식 시뮬레이터
Fig. 6. context-aware simulator

본 시뮬레이션에서는 사용자가 거부감을 가지지 않을 정도의 시간인 10일간의 비슷한 일상을 가상 공간에서 시뮬레이션을 수행하였고, 그 내용을 10개의 폴드(fold)로 저장하였다. 그리고 10점 교차검증(10-fold cross-validation)을 수행하여 성능을 검증하였다.

4.2 실험결과

실험 결과는 가상 스마트 홈에서부터 얻은 10일간의 자료를 바탕으로 베이지안 네트워크의 구조를 학습한 후에 검증하는 형태로 진행하였다. 베이지안 네트워크의 구조를 학습하는 과정에서는 상호 정보를 사용하여 각 노드간의 연결 수

에 대한 임계값으로 적용하여 노드간의 연결을 학습하였으며 이때의 성능을 비교하면 다음과 같다 (그림 7, 표 3).




그림 7. 노드 연결 수에 따른 상황인식 성능 비교
Fig. 7. results of context-aware application

표 3. 상황인식 성능 비교
Table 3. results of context-aware application

노드간 연결수	상황인식의 정확도 (%)	노드간 연결수	상황인식의 정확도 (%)
61	76.34	71	77.23
62	76.34	72	77.76
63	76.69	73	77.76
64	76.69	74	77.76
65	76.69	75	78.03
66	76.52	76	78.39
67	76.52	77	79.10
68	76.52	78	79.10
69	76.43	79	78.92
70	76.43	80	78.92

그림 7을 살펴보면 거주자의 활동 정보를 인식하는 과정에서 노드간의 연결이 많으면 더 높은 결과를 나타내는 것을 확인할 수 있다. 하지만 데이터의 저장 공간 및 메모리의 한계, 그리고 학습 자료의 부족으로 인하여 노드간의 연결수를 최대한으로 할 수가 없다.

위의 결과를 좀 더 자세하게 각 활동에 따른 인식률을 살펴보면 그림 8과 같이 나타난다.




그림 8. 각 활동에 따른 인식률
Fig. 8. recognition rate of each activities

그림 8은 각 활동의 추정된 확률 값을 나타낸 것으로서 인식 부분은 비교적 높은 확률로 활동을 인식한 경우이고 무시 부분은 한계확률보다는 낮은 확률이지만 추론된 활동 중에서는 가장 비중이 높은 경우를 나타낸다. 즉, 한계치를 설정한 경우에는 식사와 같은 경우는 전혀 인식하지 못한다고 볼 수 있으며, 한계치가 아니라 추론된 확률 중에서 가장 큰 값을 추정된 활동이라 인식할 경우에는 식사와 같은 활동도 일부 인식할 수 있다고 볼 수 있다.

하지만 앞의 그림에서 볼 수 있듯이 휴식 및 공부와 같은 활동은 사람이 가정의 카메라를 직접 보고 확인하는 경우에도 많이 구분이 힘든 상황이며 제안된 시스템으로는 전혀 인식하지 못하는 것을 볼 수 있다. 즉 제안된 시스템에서는 대부분의 경우에는 잘 인식하지만 모호성이 있는 휴식이나 독서, TV시청과 같은 경우에는 비교적 낮은 인식률을 가진다.

5. 결 론

본 논문에서는 상호정보를 이용한 베이지안 네트워크의 구조학습을 통하여 상황인식 응용을 구성하였고, 이것을 통하여 스마트 홈에서 센서 네트워크로부터의 상황인식을 할 수 있는 시스템을 제안하였다. 시뮬레이션 결과에서도 확인할 수 있듯이 센서정보를 통하여 사람이 직접보고서 판단할 수 있는 경우에는 제안된 방법으로도 쉽게 상황이 인식될 수 있었다. 즉, 제안된 방법은 개발자가 모든 상황을 관찰하고 상황인식을 할 수 있는 시스템을 구축하는 것과 비슷한 결과를 나타낸다. 이것은 상황인식에서 자동화할 수 있는 부분이 더욱 늘어나게 될 것을 의미한다.

이와 같은 보다 보편적인 상황인식 시스템의 구성과 함께 고려하여야 할 사항은 상황인식을 하는 절차나 상황인식을 사용하여 서비스를 제공할 때 편의성과 효율성만을 생각하는 것이 아니라 제안된 시스템을 사용함에 따른 거주자의 불편함, 간섭, 보안과 같은 사항도 같이 고려하여야 할 것이다.

참 고 문 헌

- [1] G. Chen and D. Kotz, "A survey of context-aware mobile computing research," Technical Report TR2000-381, Dept. of Computer Science, Dartmouth College, 2000
- [2] A. K. Dey, G. D. Abowd and D. Salber, "A context-based infrastructure for smart environments," Proc. of 1st Int. Workshop on Managing Interactions in Smart Environments(MANSE '99), pp. 14-128, 1999
- [3] E. M. Tapia, S. S. Intille, and K. Larson, "Activity recognition in the home setting using simple and ubiquitous sensors," in Proceedings of PERSASIVE 2004, vol. LNCS 3001, pp.158-175
- [4] A. Ranganathan, J. Al-Muhtadi, R.H. Campbell, "Reasoning about uncertain contexts in pervasive computing environments," IEEE Trans. on Pervasive Computing, Vol. 3, No. 2, pp. 62-70, 2004
- [5] R. E. Neapolitan, "Learning Bayesian Networks," Prentice Hall, 2004

- [6] P. Larrañaga, M. Poza, Y. Yurramendi, R. H. Murga, and C. M. H. Kuijpers, "Structure learning of bayesian networks by genetical algorithms: a performance analysis of control parameters," IEEE Trans. On Pattern Analysis and Machine Intelligence, vol 18, no 9, pp.912-926 1996.
 - [7] G. Cooper, E. Hersovits, "A bayesian method for the introduction of probabilistic networks from data," Maching Learning, vol.9, no.4. pp. 309-347, Oct 1992
 - [8] F. Fleuret, "Fast binary feature selection with conditional mutual information," The Journal of Machine Learning Research, vol. 5, Dec 2004
 - [9] A. Papoulis, S. U. Pillai, "Probability, Random Variables and Stochastic Processes," McGraw Hill, 2002
-

저 자 소 개



정우용(Woo-Yong Chung)

2004년 : 연세대학교 기계전자공학부 (학사)

2006년 : 연세대학교 전기전자공학과 (석사)

2006년~현재 : 연세대학교 전기전자공학과 박사과정

관심분야 : 퍼지 이론, 지능형 홈 네트워크

E-mail : wychung@yonsei.ac.kr



김은태(Eun-Tai Kim)

1992년 : 연세대학교 전자공학과(학사)

1994년 : 연세대학교 전자공학과(석사)

1999년 : 연세대학교 전자공학과(박사)

1999년~2002년 : 국립한경대학교 제어계측공학과 조교수

2002년~현재 : 연세대학교 전기전자공학과 교수

관심분야 : 계산지능, 지능형 로봇, 지능형 홈 네트워크

E-mail : etkim@yonsei.ac.kr