

논문 2009-04-21

# 유비쿼터스 모바일 환경에서 개인화 서비스를 위한 상황인지 추론 시스템

(Context Awareness Reasoning System for Personalized  
Services in Ubiquitous Mobile Environments)

문애경\*, 박유미, 김상기, 이병선

(Aekyung Moon, Yoo-mi Park, Sang-gi Kim, Byung-sun Lee)

**Abstract** : This paper proposed the context awareness reasoning system to provide the personalized services dynamically in a ubiquitous mobile environments. The proposed system is designed to provide the personalized services to mobile users and consists of the context aggregator and the knowledge manager. The context aggregator can collect information from networks through Open API Gateway as well as sensors in a various ubiquitous environment. And it can also extract the place types through the geocoding and the social address domain ontology. The knowledge manager is the core component to provide the personalized services, and consists of activity reasoner, user pattern learner and service recommender to provide the services predict by extracting the optimized service from user situations. Activity reasoner uses the ontology reasoning and user pattern learner learns with previous service usage history and contexts. And to design service recommender easy to flexibly apply in dynamic environments, service recommender recommends service in the only use of current accessible contexts. Finally, we evaluate the learner and recommender of proposed system by simulation.

**Keywords** : Ubiquitous Computing, Context awareness, Sensor, Personalization, Recommendation

## 1. 서 론

유비쿼터스 시대의 핵심 기술은 인간과 컴퓨터를 연결하는 상황인지(Context Awareness) 기술이다[1]. 기존의 상황인지와 관련한 주요 관심은 센서와 네트워크 망을 확보한 공급자 중심이었다[2]. 그러나, 최근에는 다양한 아이디어와 통합된 지식서비스를 기초로 하는 사용자 중심의 맞춤형 개인화 서비스로의 관심 전환이 요구되고 있다[2,3]. 궁극적

으로 상황인지의 목적은 사용자의 경험(User Experience)을 극대화하는 것으로, 이를 위해 센서와 네트워크로부터 얻어낸 사용자의 상황과 주변의 상황정보를 표현, 전송, 관리, 추론 및 분석하여 사용자의 요구사항을 최적화할 수 있는 기술 개발이 필요하다.

이러한 관점에서 본 논문은 유비쿼터스 모바일 환경에서 개인화 서비스를 능동적으로 제공하기 위한 상황인지 추론 시스템을 제안한다. 제안하는 시스템은 모바일사용자에게 개인화 서비스를 제공하기 위하여, 상황정보 수집기(Context Aggregator)와 지식관리자(Knowledge Manager)로 구성된다. 상황정보 수집기는 다양한 환경 내 위치한 센서 뿐만 아니라, Parlay X 개방형 인터페이스 (Open API) 게이트웨이를 통하여 네트워크로부터 상황정보를 수집한다. 지식 관리자는 개인화 서비스를 제공하기 위한 핵심 구성요소으로써, 사용자의 상황에

\*교신저자(Corresponding Author)

논문접수 : 2009. 06. 26., 수정일 : 2009. 07. 29.,

채택확정 : 2009. 08. 14

문애경, 박유미, 김상기, 이병선 : 한국전자통신연구원, 서비스융합연구팀

※ 본 논문은 지식경제부 및 정보통신연구진흥원의 차세대 통신네트워크 산업원천기술개발과제(2009-F-048-01)로 수행되었습니다.

최적화된 서비스를 예측하여 제공하기 위하여, 행위 추론기(Activity Reasoner), 사용자 패턴 학습기(User Pattern Learner) 및 서비스 추천기(Service Recommender)로 구성된다. 행위 추론기는 장소유형(Placetype) 정보와 사용자 직업, 시간 등의 추가적인 상황정보를 이용하여 사용자의 현재 행위를 추론하는 역할을 하는 것으로 온톨로지 추론을 이용한다. 또한 사용자 패턴 학습기는 사용자에 대한 사전 정보 혹은 추천 대상 서비스에 대한 세부정보 없이 센서를 통해 추출한 상황정보와 사용자의 서비스 사용 이력 정보(행동정보)를 학습한다. 마지막으로, 서비스 추천기는 추천시 액세스 가능한 상황정보만을 이용하여 서비스를 추천한다. 즉, 시간 및 장소 등과 같이 현재 가용한 상황정보만을 이용하여 사용자 선호 프로파일을 생성하고 이를 개인화된 서비스 추천에 이용함으로써 동적으로 변화하는 환경에 적용이 용이하다.

본 논문의 구성은 다음과 같다. 2절에서는 관련 연구를 살펴보고, 3절에서는 상황인지 추론 시스템 및 알고리즘을 제안하고, 4절에서는 모의실험 결과를 설명한다. 마지막으로 5절에서는 결론을 맺는다.

## II. 관련 연구

상황인지 컴퓨팅이라는 용어는 학계와 상업적 연구를 통해 90년대 말부터 등장하기 시작했다. 주된 연구와 활용분야로는 센서 및 GPS와 모바일 시스템을 통해서 시공간 속에 사람들의 위치를 추적해내어 위치와 관련된 서비스를 제공하려는 것이다.

MIT 미디어랩은 공간/지리적 애플리케이션 개발을 위한 PlaceMap 프레임워크를 개발하였다[4]. PlaceMap은 그림 1과 같이 사용자를 주인공으로 사용하여 지도 속에 존재하는 건물, 방문지, 지인들의 위치를 정렬한다. 지도를 구성하는 요소들은 사용자의 인증을 받은 후 지도에 표시된다. 모든 사람에게 공개되는 지도가 아닌 상황정보로 개인화된 지도로써, GPS가 부착된 휴대폰 또는 주변에 무선랜의 AP(Access Point) 위치를 기준으로 자신 및 주변 위치를 파악한다.

최근에는 차세대 네트워크의 발달과 차별화된 서비스를 요구하는 사용자의 요구에 따라 사용자와 그를 둘러싼 주변의 환경을 고려하여 사용자 중심의 개인화 서비스의 중요성이 대두되었다[3]. 개인화 서비스란 유무선이 통합되는 유비쿼터스 컴퓨팅

환경에서 다양한 장치들이 상호 연결되어 사용자의 상황정보에 따른 개인 맞춤형 서비스를 제공하는 것이다[3].

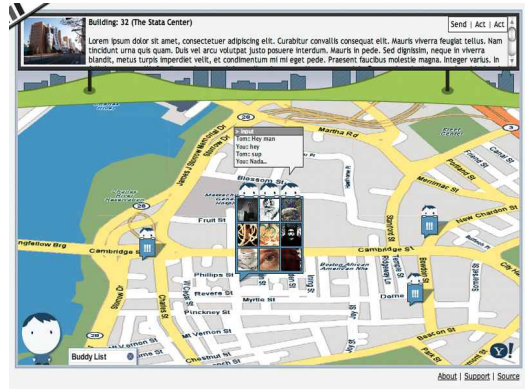


그림 1. PlaceMap의 위치관련 애플리케이션  
Fig. 1. Location related application of PlaceMap

개인화 서비스에 관련하여 서비스 자체에 대한 연구뿐만 아니라 개인화 서비스 시스템에 대한 연구도 활발하게 진행되고 있다. 대표적인 개인화 서비스 연구 프로젝트로는 Daidalos[5], eSense[6], MobiLife[7], 그리고 SPICE[8]가 있다. Daidalos는 이기종 네트워크 환경에서 끊임없는 통신 서비스와 콘텐츠 서비스를 제공하는 것을 목적으로 개발된 플랫폼으로 미리 정의된 상황정보를 이용한 call 핸들링 서비스를 제공한다. e-Sense는 3G이후의 모바일과 이질형 무선 센서 네트워크에 대하여 상황인식을 지원하기 위한 프레임워크로써, 사람이나, 사물, 환경의 상태를 체크하는 다수의 이종 센서에서 보내오는 정보들을 통합하기 위한 솔루션을 제공한다. MobiLife와 SPICE는 상황정보와 사용자 행동 학습이 필요함을 언급하고 있다. 특히 MobiLife는 상황에 적합한 서비스를 추천하기 위한 판단기준이 되는 사용자 모델을 상태 모델(Situation Model)이라고 정의하고 학습을 통해 갱신됨을 제안한다. 하지만, MobiLife에서는 응용프로그램과 상황정보에 의존적인 사용자 프로파일을 사전에 정의하고 있다[9].

학습 알고리즘을 개인화에 이용한 대표적인 연구로는 비교사 학습(unsupervised learning)을 이용한 Krause의 연구[10]와 강화학습을 이용한 Feki의 연구[11]가 있다. 비교사 학습을 이용한 경우는 특징 추출, 분류(classification) 등의 학습 방법을 통하여 사용자 상황정보를 인식한다. Krause

는 체온 등의 생리학, 음성, 움직임 행위(Activity), 위치, 그리고 스케줄의 다양한 상황정보를 비교사 학습을 통하여 학습한다. 강화학습은 사용자의 사전 정보 혹은 추천 대상에 대한 구체적인 세부정보 없이 사용자와의 상호작용만으로 학습이 가능하다. 강화학습을 추천에 이용한 대표적인 연구로는 [11-14]이 있다. 이들 대부분은 전자상거래 응용에 적용된 경우이지만, Feki는 퍼지 기반 Q-학습(Learning)을 통하여 사용자 행동을 학습하고, 로봇의 추천 시스템에 적용하였지만, 사전에 정의된 상태에서만 추천한다[11].

### III. 상황인지 추론 시스템

#### 3.1 시스템 구조

본 논문에서 제안한 상황인지 추론 시스템 및 상황정보 기반 개인화 서비스를 이해하기 위하여, 먼저 유비쿼터스 환경 하의 모바일 사용자에게 발생할 수 있는 시나리오를 이해할 필요가 있다. 이를 위해 아래 [예 1]의 시나리오를 살펴보자.

[예 1] 오후 7시 퇴근 무렵, 오대리는 비가고 있는 테헤란로를 걷고 있다. 그가 휴대폰을 열자, 화면에는 “레스토랑”, “택시”, “자하철”의 3가지의 라벨이 달린 서비스 버튼이 강조되어 표시된다. 비가 오는 날 차를 운전하지 않는 오대리의 성향을 알고 있는 시스템은 집으로 귀가를 위해 주변에 콜택시 정보와 부근 지하철역에 대한 대중 교통정보를 안내한다 [2].

[예 1]은 상황인지 기술이 지향하고 있는 미래를 가상하여, 구현된 서비스의 모습을 보여준다. 사용자의 선호도, 서비스 사용 이력(history) 정보에 기반을 둔 시스템은 현재의 시간, 장소, 날씨, 주변의 교통정보와 같은 상황정보를 이용하여 사용자가 원하는 서비스를 동적으로 구성해 준다. 즉, 현재의 시간과 위치에서 발생 가능한 상황정보를 비교 및 분석하여 “레스토랑”, “택시”, “지하철”의 3가지 서비스를 추천함으로써, 사용자의 요구를 만족시켜주는 서비스와 연결을 가능하게 한 것이다.

[예 1]의 서비스를 제공하기 위해서는 센서나 네트워크의 정보를 수집하여 사용자의 현재 행위를 추론하고, 사용자의 서비스 이용 패턴을 분석하여, 서비스를 예측하여 제공하는 시스템이 필요하다. 이를 위해, 본 상황인지 추론 시스템은 그림 2와 같이 상황 정보 수집기(Context Aggregator), 지식

관리자(Knowledge Manager)로 구성된다.

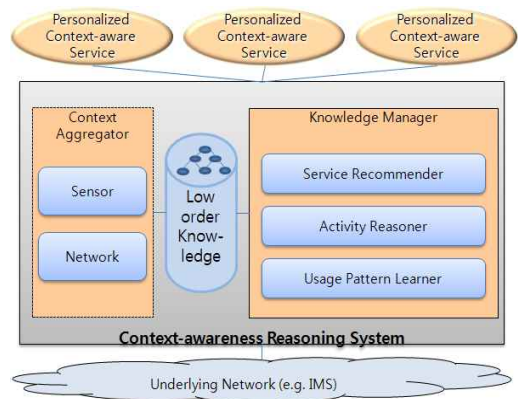


그림 2. 상황인지 추론 시스템의 구조

Fig. 2. A architecture of context awareness reasoning system

#### 3.2 상황정보 수집기

상황정보 수집기는 여러 다양한 유비쿼터스 환경 내 위치한 센서로부터 정보를 얻고 그 정보를 하위계층지식(Lower Order Knowledge)화 한다. 하위계층지식은 추론, 학습 등의 지식 처리 기능에 의해 가공되기 이전의 초기 정보를 의미한다. 네트워크 상황 정보 수집기는 그림 3과 같이, Parlay X 개방형 인터페이스 (Open API) 게이트웨이를 통하여 IMS HSS, LBS Presence 서버 등으로부터 사용자의 상황정보를 수집한다. 개방형 인터페이스란 응용 서비스 계층과 네트워크의 전달망 계층 사이의 표준화된 인터페이스를 의미하며, 네트워크의 기능들을 추상화시킨 인터페이스로서 이를 이용하여 다양한 통신망 (유선전화망, 이동전화망, 데이터 통신망, 방송망 등)의 기능 및 정보를 액세스할 수 있다.

HSS/LBS의 네트워크의 위치 정보 서버로부터 획득한 단말에 대한 위치(위도, 경도 좌표값)를 해당 단말을 소유한 사용자의 위치로 가정한다. (위도, 경도) 좌표로 구성된 사용자 위치 정보는 지오코딩(Geocoding)을 통하여 사회적 주소로 변환한다. 지오코딩이란 지리적 좌표값(위도37.423021, 경도 -122.083739)을 사회적 주소 ("1600 Amphitheatre Parkway, Mountain View, CA")로 바꾸는 것을 의미한다. 변환된 사회적 주소는 사회적 위치 온톨로지를 이용하여 해당 위치의 장소유형을 추출한다. 사회적 주소와 장소유형을 매핑하기

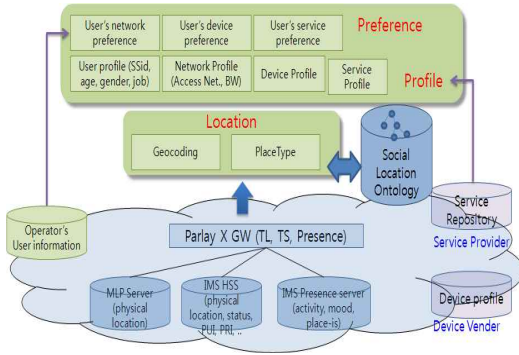


그림 3. 네트워크로부터 수집 가능한 정보

Fig. 3. Information to be acquired form network

위하여 온톨로지로 구성하지 않아도 되지만, 한 장소가 여러 가지 장소유형 정보를 가질 수도 있고, 장소유형이 추가되는 경우도 있기 때문에 데이터베이스 모델에 비해 온톨로지로 정의하는 것이 효과적이다.

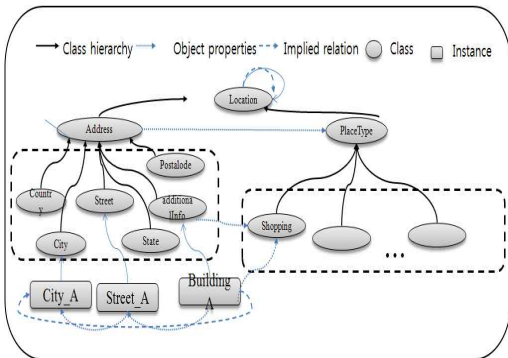


그림 4. 사회적 주소 온톨로지

Fig. 4. Social address ontology

그림 4는 사회적 주소 온톨로지 모델을 나타낸다. 사회적 주소 온톨로지는 지오코딩에 의해 추출한 사회적 주소 정보를 저장하기 위하여, 주소의 계층구조와 장소유형 정보를 갖는다. 이를 위해 사회적 주소 온톨로지는 그림 4와 같이 주소(Address)와 장소유형(PlaceType) 클래스로 구성된다. 사회적 주소 온톨로지는 주소 인스턴스 간의 계층 구조를 표현하기 위하여 이행속성(Transitive property)을 사용하여 정의한다. 이행속성은 속성 P가 이행적이고, CityA, StreetA, BuildingA라는 인스턴스가 CityA-P-StreetA 그리고 StreetA-P-BuildingA라는 형태로 연결되어 있을 때, CityA-P-BuildingA

라는 관계를 자동적으로 추론할 수 있다. 또한, 사회적 주소의 계층을 표현하기 위하여 다음 표 1과 같은 서브클래스로 구성된다.

표 1. 사회적 주소 표현을 위한 클래스

Table. 1. Class for expressing social address

이름	내용
Country	국가 코드
State	국가 행정구역, 주, 도,
City	시
Street	거리, 동
AdditionalInfo	추가적인 위치 정보 (빌딩명, 회사이름)
Code	우편번호

장소유형은 IETF에서 정의한 프레즌스를 참조하여 다음과 같이 구성될 수 있다[15].

- 항공기, 공항, 전시장, 자동차, 은행, 바, 자전거, 버스, 버스정류장, 카페, 교실, 클럽, 관공서, 병원, 호텔, 오토바이, 공장, 주차장, 공공교통, 레스토랑, 학교, 쇼핑지역, 기차역, 극장, 집, 실외, 교회, 도서관, 기차, 창고(도매점), 선박, 바다, 스타디움, 사무실, 지하철 등

### 3.3 지식관리자

지식관리자는 상황인지 개인화 서비스를 제공하기 위한 핵심 구성요소으로써, 사용자에게 최적화된 서비스를 예측하여 제공하기 위한 역할을 한다. 이를 위해 행위 추론기, 사용자 패턴 학습기 그리고 서비스 추천기로 구성된다.

#### 3.3.1 행위 추론기

행위 추론기는 센서 및 네트워크 상황 정보를 수집하여 사용자가 처한 상황 (Situation)을 추론하는 역할을 제공한다. 본 논문에서 제안하는 행위 추론기는 장소유형 정보와 사용자 직업, 시간 등의 추가적인 상황정보를 이용하여 사용자의 현재 행위를 추론하는 역할을 하는 것으로 온톨로지 추론을 이용한다.

IETF 프레즌스를 참조하여 운전, 회의, 쇼핑, 대중교통, 업무, 식사, 예배 등의 사용자 행위를 정의하고, 그림 5와 같이 Person In Meeting(회의), Person In Shopping(쇼핑), Person In Wating For Bus(대중교통), Person In Working(업무)의 4가지 행위에 대한 추론 규칙(Rule)으로 구성한다. 예를 들면, 'Person In Meeting(회의)'은 위치, 역할, 스케줄

그리고 디바이스 상태와 같은 주어진 상황정보를 기반으로 추론될 수 있다. 제한한 4가지 행위는 온톨로지의 TBox(Terminological Box) 규칙을 이용하여 정의되고, 사용자의 상황정보가 변경되면 추론된다.

온톨로지는 TBox와 ABox(Assertiona Box)로 구분이 되는데, TBox는 온톨로지의 스키마를, ABox는 인스턴스를 나타낸다. TBox 추론이란 subsumption 관계를 추론하는 것을 의미하는데 이 과정에서 클래스와 서브클래스의 관계를 추론하게 된다. Subsumption 추론은 하나의 클래스가 다른 클래스를 포함하는 것을 의미한다. TBox 추론 규칙에 따라 추론결과 사용자 클래스의 서브 클래스에 Person In Shopping, Person In Working, Person In Wating For Bus, Person In Meeting 서브클래스가 생성된다. 즉, 특정 행위 클래스에 속하는 사용자의 경우 다수의 클래스 타입을 가질 수 있어 어떤 사용자는 Person In Working 클래스와 Person In Meeting 클래스 모두에 속할 수도 있다.

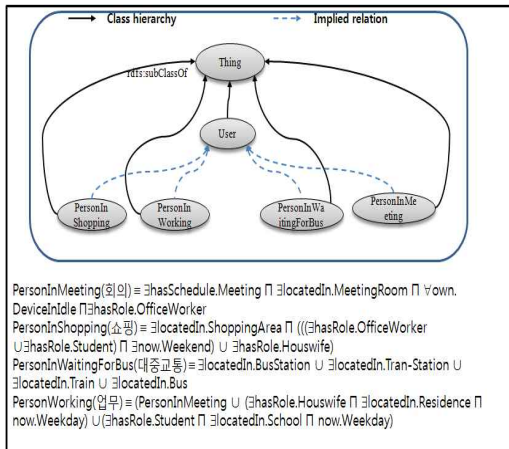


그림 5. 사용자 행위 클래스 및 추론 규칙  
 Fig. 5 User activity class and reasoning rules

행위 추론에서 단순하게 장소유형만을 가지고 사용자의 행위를 결정할 수 있다. 하지만, 복합적인 장소유형을 가지는 경우에는 스케줄, 직업, 시간 등의 추가적인 정보를 이용하여 추론한다. 예를 들면, 사용자가 “코엑스”에 도착한 경우, “코엑스”의 장소유형이 “회의장”과 “쇼핑 지역”등 복합적으로 가지는 경우, 장소유형 정보만으로 사용자의 행위 추론이 어렵다. 이러한 경우, 사용자의 스케줄, 주변 사람들, 시간 등의 추가 정보로서 사용자의 상황이 “쇼핑”인지 혹은 “회의”인지를 판단한다. 즉, 사용자가 위치

한 장소의 유형이 미팅룸이고 스케줄에 미팅이 있고, 직업이 직장인(officeworker)인 경우, “회의” 행위라고 추론할 수 있을 것이다.

### 3.3.2 사용자 패턴 학습기

사용자의 피드백을 바탕으로 사용자 패턴 학습 알고리즘은 표 2와 같다. 강화학습의 기본 개념[16]을 활용하여 사용자에 대한 사전 정보 혹은 추천 대상에 대한 구체적인 세부정보의 필요 없이 상황정보와 사용자의 서비스 이력 정보를 이용해서 학습한다. 단, 사용자의 서비스 이력 정보도 프라이버시 문제가 존재하기는 하지만 허락한 사용자에 한해서 시스템에서 이용할 수 있는 정보라고 가정한다.

표 2. 사용자 패턴 학습기 알고리즘  
 Table 2. Algorithm of user pattern learner

```

Service_Usage_Learner(history, ui)
INPUT Service usage history contains {set of context, service svc, reward r} for user i
OUTPUT learnt value sets of service for user i on context, C-TBLi
Context= {c1, ..., cn}, 1 ≤ n,
ck: kth context in the state
Attributes(ci)={ai,1, ... ai,k}, 1 ≤ k and 1 ≤ i ≤ n
Service Category = {svc1, ..., svcn}.
Reward r = {Selection-rs,
PositiveFeedback-rp, NegativeFeedback-rn}.
for each ck in C-TBLi[ak,i(t)][svc(t)] do
C - T B L i [ a k , i ] [ s v c ( t ) ] ←
C-TBLi[ak,i(t)][svc(t)]+ αR(t),
where α is the discount factor and ck ∈ States.
RETURN C-TBLi;
    
```

본 알고리즘은 입력으로 사용자 식별자, 상황정보, 사용서비스, 보상값(reward)으로 구성되는 이력 정보를 갖는다. 시스템과 사용자간 상호작용에 의한 보상 값 R을 사용자 행위에 의존하여 다음과 같이 3가지로 구분하여 정의한다. 첫째, 사용자가 명시적으로 해당 서비스를 선택한 경우로 rs로 정의한다. 둘째, 사용자에게 시스템이 특정 서비스를 추천하고 사용자가 해당 서비스에 긍정적인 반응을 보이는 경우

로 rp로 정의한다. 마지막으로 사용자에게 시스템이 특정 서비스를 추천하고 사용자가 해당 서비스에 부정적인 반응을 보이는 경우로 rn으로 정의한다.

Attributes(ci)는 상황정보 ci가 가지는 속성값으로, 이산값을 가지는 경우와 연속 값을 가지는 경우로 구분된다. 예를 들면, 상황정보가 추론된 사용자 행위, 장소(location), 시간으로 구성된다 가정하면, 사용자 행위와 장소는 이산값을 가지는 경우에 해당되고 시간, 온도는 연속적인 데이터 값으로 표현되기 때문에 이산값으로 맵핑하기 위한 정규화가 필요하다[17].

학습단계에서 강화학습의 기본 개념에 따라, 미리 설정된 모델 없이 보상값만으로 서비스 사용 로그 C-TBL을 구성한다. C-TBL은 [상황정보-서비스]의 이차원 배열들의 집합으로 구성되는 데, 다음 그림 6은 C-TBL의 구성 예를 보여준다.

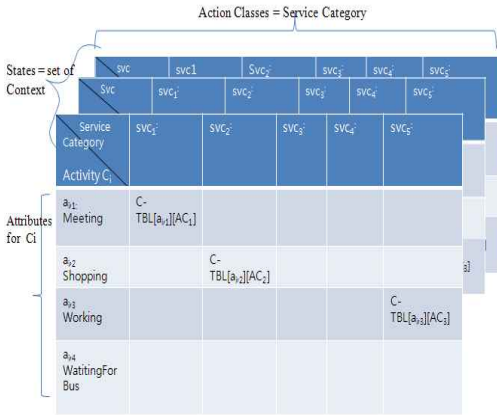


그림 6. C-TBL 구성 예  
Fig. 6. Example of C-TBL

3.3.3 서비스 추천기

서비스 추천기는 학습을 통하여 획득한 사용자 패턴 정보 C-TBL을 이용하여 현재 상황에서 혹은 가까운 미래에 사용자가 선호할만한 서비스를 예측하여 제공하는 역할을 한다. 예를 들어, 사용자의 가족이 국제공항에 도착했다고 가정하자. 그러면 그들이 휴가중이고 여행이 목적이라면, 목적지에 도착할 때, “Travel Information” 서비스를 예측하여 사용자의 단말기에 능동적으로 제공할 수 있을 것이다.

서비스 추천기는 학습된 C-TBL로부터 특정 상황에서 개인화 서비스를 추천하기 위하여 P-TBL을 정의한다. P-TBL은 현재 상태 정보를 입력 받아, 이 상태에 속하는 상황정보에 대해 각 서비스에 대한 선

호도 값을 갖는다. 현재 상태(current situation:cs)라고 하면, ai∈cs이고 P-TBL은 다음 식과 같이 계산된다. N(cs)는 C-TBL을 이용하여 P-TBL을 구성할 때, 각 값들을 0~1 사이의 값을 갖도록 정규화하기 위한 값이다. 가중치 wi는 정보이득(Information gain)을 이용하여 상황정보 별로 조절한다[18]

$$P-TBL[svc_k] = N(cs) \sum_{a_i \in cs} w_i \times C-TBL[a_i][svc_k]$$

가장 큰 값을 가지는 서비스 svc =(Maxsvc (P-TBL[svc]))를 사용자에게 추천하거나, P-TBL[svc] 값의 순서를 매겨 선호 서비스 목록을 사용자에게 제공할 수 있을 것이다. 추천한 서비스에 대한 사용자 피드백이 있는 경우, 사용자의 반응이 긍정적/부정적 이냐에 따라 학습기에 보상값 rp, rn을 반영할 수 있다. 하지만, 사용자로부터 피드백을 받기 위한 구체적인 방법은 서비스 제공자 혹은 응용프로그램에서 제공한다고 가정한다.

IV. 실험

유비쿼터스 컴퓨팅 환경의 실제 사용자를 대상으로 제안한 학습기와 추천기의 성능을 평가해야 하지만, 개인정보 획득에 어려움이 있다. 따라서 본 논문에서는 모의실험을 통해 제시된 알고리즘의 성능을 평가한다. 모의실험은 UCI machine learning depository [19]에서 선택한 데이터(Create Approval, Ballons, Balance, Iris, Wine)를 사용한다. 이 중에서 Iris, wine은 학습 기법 평가에 가장 많이 쓰이는 데이터 중에 하나이다. 그리고 제시된 사용자 프로파일의 알고리즘과 비교할 알고리즘은 [20]를 참조하여 J48, ZeroR, NaiveBayes, 그리고 SMOSupport Vector Machine을 선택하였다. 이들 알고리즘은 Weka3 tool-kit[21]을 사용하여 평가한다. J48은 C4.5 decision tree를 생성하고 선택하는 알고리즘이고, NaiveBayes는 확률에 근거한 분류 방법으로, 아이템에 대하여 분류별로 속할 확률을 계산하여 계산된 확률 중 가장 높은 확률을 가지는 분류를 선택한다. ZeroR은 이산 데이터의 경우 절대 다수(majority) 클래스를, 연속 데이터인 경우는 평균 클래스를 선택한다[20].

본 실험에서 사용하는 성능평가 지수는 정확도(Precision)이다. R은 사용자에게 추천되는 개수이고 RP(Recommended Preference)는 추천 값과 실제 값이 일치하는 경우라고 할 때 정확도는 RP/P로 계산하여 %값으로 나타낸다. 신뢰성 있는 모의 실험

험결과를 얻기 위하여 k-fold cross validation을 적용하여 10회(k=10) 실험한 결과의 평균값을 측정한다.

실험 데이터를 살펴보면, Create approval의 경우, 15개의 상황정보와 9개의 이산 데이터로 구성되고, 추천대상이 되는 서비스는 3개로 볼 수 있다. 표 3은 실험에 사용되는 데이터에 대한 인스턴스 수와 상황정보 수 그리고 각 상황정보중 이산값을 가지는 개수를 나타낸다. 이산값을 가지는 경우를 제외한 나머지는 연속 값을 가지는 상황정보를 나타낸 것으로 볼 수 있다.

표 3. 실험 데이터 구성 정보

Table 3. Information of simulation data

Data	Instance	Attr.(Categorical)	Service category
Create Approval	665	15(9)	2
Balloons	20	4(4)	2
Balance	625	4(4)	3
Iris	150	4(0)	3
Wine	178	13(0)	3

본 논문에서는 연속값을 가지는 데이터의 경우에 고정된 구간으로 정규화하는 경우와 구간의 개수를 상황정보 애트리뷰 값에 따라 임의의 k로 조정하는 경우[17]의 두 가지로 구현하였다. 전자를 Learner-S, 후자를 Lerner-Q로 정의한다. 그림 7과 8은 모의 실험 결과를 나타낸다. 그리고 보상값을 단순화하기 위하여 rs를 1로 고정하고, rn, rp는 고려하지 않는다. 그림 7은 이산 데이터만 가지는 상황정보를 대상으로만 실험한 경우의 성능을 나타낸 것이다. 본 논문에서 제시한 기법은 전체적으로 다른 알고리즘에 비해 좋은 성능을 보인다. 특히, ZeroR에 비해 1.5배정도 성능이 개선되었다. Create approval 데이터에서는 Learner의 정확도는 86.8%이다. 그림 8은 연속 데이터만을 뽑아서 실험한 것이다. Learner-Q는 iris와 wine 데이터에서 다른 알고리즘에 비해 성능이 좋다. wine 데이터의 경우, J48에 비해서는 약간 개선되었지만, ZeroR 알고리즘에 비해 2.4배 개선되었다. Wine 데이터에서 Learner-Q는 Lernerr-S에 비해 1.2배 성능이 향상되었다.

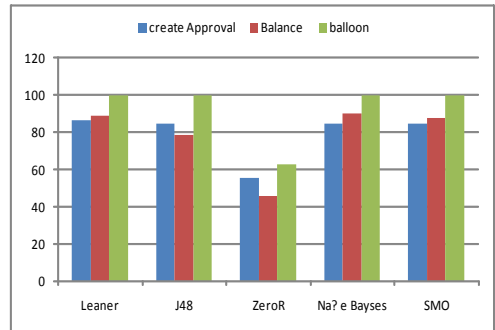


그림 7. 이산 값을 가지는 데이터의 실험결과  
Fig. 7. Experiment results of discrete data




그림 8. 연속 값을 가지는 데이터의 실험결과  
Fig. 8. Experiment results of continuous data

## V. 결 론

본 논문은 유비쿼터스 모바일 환경에서 개인화 서비스를 능동적으로 제공하기 위한 상황인지 추론 시스템을 제안한다. 모바일 사용자에게 개인화 서비스를 제공하기 위하여 제안한 시스템은 상황정보 수집기와 지식관리자로 구성된다. 제안된 상황정보 수집기는 Parlay X 개방형 인터페이스 게이트웨이를 통하여 네트워크로부터 상황정보를 수집하고, 지오코딩과 사회적 주소 온톨로지를 이용하여 주소유형을 추출함으로써 사용자 행위추론에 도움을 준다. 지식 관리자의 사용자 패턴 학습기는 강화학습의 기본개념을 활용하여 상황정보와 사용자의 서비스 이력 정보만을 이용하여 학습한다. 동적으로 변화하는 환경에 적용이 용이하도록, 서비스 추천기는 추천 시 액세스 가능한 상황정보만으로 서비스를 추천한다.

본 시스템의 성능을 평가하기 위하여 UCI machine learning depository에서 선택한 데이터와

Weka3를 이용하여 타 학습 알고리즘과 모의실험을 수행하였다. 주요한 결과들을 요약하면 다음과 같다. 첫째, 이산 값을 가지는 상황정보만을 대상으로 한 경우, 제안기법은 다른 알고리즘에 비해 비교적 좋은 성능을 보인다. 둘째, 연속적인 데이터의 경우, 데이터의 특성을 고려한 정규화 방법은 다른 알고리즘에 비해 비교적 좋은 성능을 보인다 하지만, 데이터 특성을 고려하지 않은 고정된 정규화는 성능 저하를 초래할 수도 있다.

### 참고문헌

- [1] A. Moon, H. Kim, H. Kim and S. Lee, "Context-Aware Active Services in Ubiquitous Computing Environments," *ETRI Journal* vol. 29, no. 2, 2007, pp. 169-178.
- [2] 홍일영, "상황인지 소프트웨어, 이제 몸짓을 넘어 마음을 읽어야 한다!" 한국 소프트웨어 진흥원, 정책연구센터, 2008.
- [3] 박재영 외 4인, "국외 개인화 서비스 기술 동향," TTA 저널/정보통신표준화소식, 2008.
- [4] <http://context.media.mit.edu/press/>.
- [5] S. McBurney, M. Williams, N. Taylor and E. Papadopoulou, "Managing User Preference for Personalization in a Pervasive Service Environment," *IEEE Advanced International Conf. on Telecommunications*, 2007.
- [6] e-Sense, "Capturing Ambient Intelligence for Mobile Communications through Wireless Sensor Networks," *IST*, 2006.
- [7] IST-2004-511607 *MobiLife D27b (D4.1b) v1.0*, 2004.
- [8] SPICE, Deliverable N°: 2, "Title: Specification of pro-active Service Infrastructure for Attentive Services," 2007.
- [9] M. Sutter, O. Droegehorn and K. David, "User Profile Management on Service Platforms for Ubiquitous Computing Environment," *IEEE Conf. Vehicular Technology*, 2007 pp. 287-291.
- [10] A. Krause, A. Smailagic and D. Siewiorek, "Context-Aware Mobile Computing: Learning Context-Dependent personal Preferences from a Wearable Sensor Array," *IEEE Trans. on Mobile Computing*, 5(2), 2006, pp. 113-127.
- [11] M. Feki, S. Lee, Z. Bien and M. Mokhtai, "Context Aware Life Pattern Prediction Using Fuzzy-State Q-Learning," *LNCS4541*, 2007, pp.185-195.
- [12] N. Golovin and E. Rahm, "Reinforcement Learning Architecture for Web Recommendations," *Conf. in Information Technology: Coding and Computing*, 2004.
- [13] F. Herndex, E. Gaudioso and J. Boticario, "A Reinforcement Learning Approach to Achieve Unobtrusive and Interactive Recommendation Systems for Web-Based Communities," *LNCS3137*, 2004, pp. 409-412.
- [14] P. Rojanavas, P. Srinil and O. Pinnern, "New Recommendation System Using Reinforcement Learning," *eBusiness*, 2005.
- [15] Henning Schulzrinne, Vijay Gurbani, Paul Kyzivat, and Jonathan Rosenberg, "RPID: Rich Presence Extensions to the Presence Information Data Format (PIDF)," *IETF RFC 4480*, July 2006.
- [16] L. Kaelbling, M. Littman and A. Moore, "Reinforcement Learning: A Survey," *Journal of Artificial Intelligence Research*, vol. 4, 1996, pp. 237-285.
- [17] S. Nguyen and A. Skowron, "Quantization of Real Value Attributes," *Joint Annual Conf. Information on Sciences*, 1995, pp. 34-375.
- [18] K.Jearanaitanakij and O. Pinnern, "An Information Gain Technique for Acceleration of Convergence of Artificial Neural Networks," *ICICS*, 2005, pp. 349-352.
- [19] <http://archive.ics.uci.edu/ml/>.
- [20] S. Louis, A. Shankar, "Context Learning Can Improve User Interaction, Information Reuse and Integration," *IEEE conf. IRI 2004*, pp. 115-120.
- [21] <http://www.cs.waikato.ac.nz/ml/weka>.



저 자 소 개

**문 애 경 (Aekyung Moon)**



1992년 영남대학교 전산공학과 졸업 (공학 학사)  
1996년 영남대학교 컴퓨터공학과 졸업 (공학 석사)  
2000년 영남대학교 컴퓨터공학과공학과 졸업 (공학 박사)

2000년 ~ 현재 한국전자통신연구원 융합기술연구부분 선임연구원  
관심분야 : 분산/병렬 데이터베이스, 메시징시스템, 개인화 기술, 상황인지 기술  
Email : akmoon@etri.re.kr

**박 유 미 (Yoo-mi Park)**



1991년 2월 숙명여자대학교 전산학과 졸업  
1997년 8월 충남대학교 컴퓨터공학과 석사  
1991년 3월~현재 한국전자통신연구원 책임연구원

관심분야 : 개방형 서비스 기술, 개인화 서비스, SIP  
Email : parkym@etri.re.kr

**김 상 기 (Sang-gi Kim)**



1981년 2월 서울대학교 산업공학과 학사  
1983년 2월 서울대학교 산업공학과 석사  
2007년 6월 한국정보통신대학교 IT경영학부 박사  
1984년 ~ 현재 한국전자

통신연구원 서비스융합연구팀장  
관심분야 : 서비스 플랫폼, 서비스 사이언스  
Email : kimsang@etri.re.kr

**이 병 선 (Byung-sun Lee)**



1980년 성균관대학교 수학과 학사  
1982년 동국대학교 전산학과 석사  
2003년 한국과학기술원 전산학과 박사  
2000년 ~ 2006년 MSF

이사  
1982년 ~ 현재 한국전자통신연구원 (현 융합서비스플랫폼연구부장)  
관심분야 : 차세대 통신서비스 기술, 서비스 융합, 지식서비스 플랫폼, 서비스 사이언스  
Email : bslee@etri.re.kr