

# 유비쿼터스 컴퓨팅 환경에서 개인화를 위한 상황정보 기반 사용자 프로파일

정회원 문애경\*, 김형환\*, 종신회원 박주영\*, 정회원 최영일\*

## Context Based User Profile for Personalization in Ubiquitous Computing Environments

Aekyung Moon\*, Hyunghwan Kim\* *Regular Members*, Juyoung Park\* *Lifelong Member*,  
Young-il Choi\* *Regular Member*

### 요약

본 논문은 사용자에게 ‘상황에 따른 개인화된 서비스’를 추천하기 위한 사용자 프로파일을 제안한다. 제안하는 사용자 프로파일은 상황정보와 사용자의 서비스 사용 정보를 ‘학습’하여 생성된 [상황 정보, 서비스]의 이차원 조합으로 표현되며, 사용자에게 서비스를 ‘추천’하고자 할 때 사용된다. 학습단계에서는 강화학습의 기본 개념을 활용하여 미리 설정된 모델 없이 행동과 보상 값만으로 사용자 프로파일을 구성하며, 추천단계에서는 시간 및 장소 등의 현재 가용한 상황정보와 학습된 사용자 프로파일을 이용하여 현재 상태에서 사용자가 선호할 만한 서비스 목록을 생성하고 가장 높은 선호도 값을 갖는 서비스를 추천한다. 끝으로 본 논문에서 제안하는 학습 및 추천 알고리즘을 검증하기 위해 UCI 데이터를 사용한 모의 실험을 통해 Weka tool-kit의 주요 알고리즘들과 성능을 비교한다.

**Key Words :** Ubiquitous Computing; Context-aware; Sensor; Recommendation System

### ABSTRACT

We proposed the context based user profile which is aware of its user's situation and based on user's situation it recommends personalized services. The user profile which consists of {context, service} pair can be acquired by the context and the service usage of a user; it then can be used to recommend personalized services for the user. In this paper, we show how they can be evolved without previously known user information so that not to violate privacy during the learning phase; in the result our user profile can be applied to any new environment without any modification to model only except context profiles. Using context-awareness based user profile, the service usage pattern of a user can be learned by the union of contexts and the preferred services can be recommended by the current environments. Finally, we evaluate the precision of proposed approach using simulation with data sets of UCI depository and Weka tool-kit.

### I. 서론

본 논문에서는 유비쿼터스 컴퓨팅 환경에서 개인화 서비스를 능동적으로 제공하기 위한 상황정보(context)

기반의 사용자 프로파일을 제시하고 이를 위한 학습 및 추천 알고리즘을 제안한다. 현재 많이 사용되고 있는 개인화 기법으로는 내용기반(content-based)과 협업 (collaborative) 필터링이 있고, 이를 대부분이 사용자

\* 본 연구는 지식경제부 및 정보통신연구진흥원의 차세대통신네트워크 산업원천기술 개발 과제(2009-F-048-01)로 수행되었습니다.

\* 한국전자통신연구원 융합기술연구부문 서비스융합연구팀(akmoon@etri.re.kr, hhkim@etri.re.kr, jypark@etri.re.kr, yicho@etri.re.kr)

논문번호 : KICS2008-10-473, 접수일자 : 2008년 10월 23일, 최종논문접수일자 : 2009년 4월 21일

에 대한 사전 정보 혹은 추천 아이템에 대한 세부 정보가 필요하다<sup>[1,2]</sup>. 내용기반 필터링을 서비스 추천에 적용하기 위해서는 서비스에 대한 세부 항목을 정의해야 하고, 이를 위한 도메인 지식이 필요하다. 또한, 협업 필터링을 적용하기 위해서는 다른 사용자의 정보가 필요한데, 보안이나 프라이버시의 문제로 인하여 사용자들에 대한 사전 정보 수집이 어렵다. 이러한 문제를 해결하기 위하여 본 논문은 사용자에 대한 사전 정보 혹은 추천 대상 서비스에 대한 세부정보 없이 센서를 통해 추출한 상황정보와 사용자의 서비스 사용 정보(행동정보)를 학습한 상황정보 기반 사용자 프로파일을 제안한다.

본 논문에서 제안한 상황정보 기반 사용자 프로파일은 사용자와 상호작용 과정을 거치면서 적용한다는 점에서 강화학습을 기본 개념으로 한다. 제안된 사용자 프로파일은 사용자와의 상호작용을 통해서 사용자의 서비스 선호도를 학습하여 생성되고, 사용자에게 상황에 따른 서비스를 능동적으로 추천하는 데 사용된다. 학습 단계에서 [상황정보, 서비스]의 이차원 배열로 사용자 프로파일 정보를 구성하고, 사용자가 서비스를 선택한 경우인지, 시스템이 서비스를 추천한 경우에 대한 피드백인지에 따라 해당 서비스에 대한 보상 값을 결정하고 학습한다. 또한 다양한 환경에 적용이 용이하도록, 상태는 환경 내에 설치된 센서들로부터 추출한 상황정보들로 구성한다. 추천이 필요한 상태에서 액세스 가능한 상황정보만으로 학습된 사용자 프로파일로부터 서비스를 추천한다. 즉, 시간 및 장소 등과 같이 현재 가용한 상황정보만을 이용하여 사용자 선호 프로파일을 생성하고 이를 개인화된 서비스 필터링에 이용함으로써 동적으로 변화하는 환경에 적용이 가능하다. 또한 사용자에 따른 상황정보 별 중요도를 서비스 선택에 반영하기 위하여 정보이득(information gain)을 고려한다.

본 논문의 구성은 다음과 같다. 2절에서는 관련 연구를 살펴보고, 3절에서는 상황정보 기반 프로파일과 학습 및 추천 알고리즘을 제안하고, 4절에서는 모의실험 결과를 설명한다. 마지막으로 5절에서는 향후 연구방향 및 결론을 맺는다.

## II. 관련 연구

개인화 서비스란 유무선이 통합되는 유비쿼터스 컴퓨팅 환경에서 다양한 장치들이 상호 연결되어 사용자의 상황정보에 따른 개인 맞춤형 서비스를

제공한다<sup>[3]</sup>. 본 절에서는 사용자 상황정보 이용에 관한 기존 연구와 상황정보 기반 개인화 연구 내용을 설명한다.

### 2.1 사용자 상황정보 연구

사용자 상황정보에 대한 대표적인 연구사례는 다음과 같다. Wizard of Oz 연구는 음성 및 영상 데이터를 상황정보로 이용하여 사용자 개입(user interruptibility) 시점을 결정하는 사용자 모델을 제시한다<sup>[4]</sup>. Hudson은 도어의 상태, 폰 상태, 소음 감지 등의 사무실 기반 센서와 키스트로크(keystroke)와 마우스의 움직임을 통해 컴퓨터 사용 상태를 분석하여 Oz에 제시된 사용자 모델을 구현하였다<sup>[5]</sup>. SenSay는 상황정보 기반 call 핸들링 서비스를 제안한 것으로, 사용자의 상태에 따라 핸드폰의 상태를 결정한다. 웨어러블 센서를 이용하여 상황정보를 추출하고, 사용자를 대신하여 걸려온 전화를 수락할지 아니면 거절할지를 선택한다<sup>[6]</sup>. 이를 위해, SenSay는 개입금지(uninterruptible), 활동중(High-energy), 휴식중(idle) 그리고 일상(normal)으로 구성된 4가지 형태의 고정된 사용자 모델을 사용한다. 이 경우 사용자의 상태에 따라 능동적으로 서비스를 제공하지만, 동일한 상태의 사용자들에 대하여 동일한 서비스를 제공하므로 진정한 의미의 개인화 서비스라고 보기 어렵다<sup>[6]</sup>. 그 외 사용자 상황정보를 수집하기 위한 많은 연구가 진행되고 있다. 그 중에서 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<sup>[7]</sup>.

### 2.2 상황정보 기반 개인화 서비스 연구

현재 많이 사용되고 있는 대표적인 개인화 기법은 내용기반 추천(content-based)과 협업 추천(collaborative)으로 나누어진다<sup>[11]</sup>. 내용기반 추천은 사용자의 프로파일과 추천의 대상이 되는 아이템의 구성요소를 비교하여 유사도가 높은 것들을 추천하는 기법이다. 협업 추천은 추천의 대상이 되는 목표 사용자와 비슷한 프로파일을 가진 다른 사용자를 찾아 그 사용자가 높은 평가를 매긴 아이템을 목표 사용자에게 추천하는 방법이다. 이 외에 사용자의 성별, 나이, 직업 등의 인구통계학적 정보를 활용하여 추천을 하는 인구통계학적 추천 기법과 내용 기반 추천과 협업 추천을 결합한 하이브리드 추천 기

법 등이 있다. 이들 대부분이 사용자에 대한 사전 정보 혹은 추천 아이템에 대한 세부 정보가 필요하다<sup>[1,2]</sup>. 또한 기존 연구는 사용자의 명시적인 요구에 따라 사용자 프로파일 정보를 활용하여 컨텐츠 정보를 추천하는 데 중점을 두고 개발되었으며, 전자상거래, 웹서비스 등의 정적인 환경에서 정제된 데이터를 입력 받는 것을 가정하기 때문에 상황정보와 사용자의 행동 패턴을 분석하여 동적인 환경에서도 적용 가능한 사용자 모델을 지원할 수 있는 기술이 필요하다. I-centric에서도 사용자의 행동을 학습하여 선호도 정보를 생성하는 것을 개인화 기술로써 제시하였다<sup>[3]</sup>.

대표적인 개인화 서비스 플랫폼 연구 프로젝트로는 Daidalos<sup>[9]</sup>, MobiLife<sup>[10]</sup>, 그리고 SPICE<sup>[11]</sup>가 있다. Daidalos는 이기종 네트워크 환경에서 끊김없는 통신 서비스와 컨텐츠 서비스를 제공하는 것을 목적으로 개발된 플랫폼으로 미리 정의된 상황정보를 이용한 call 헌들링 서비스를 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 있어<sup>[12]</sup>, 유연성에 문제점을 갖는다.

학습 알고리즘을 개인화에 이용한 대표적인 연구로는 iDorm<sup>[13]</sup>과 Neural Network House<sup>[14]</sup>가 있다. iDorm의 경우는 미리 정해져 있는 퍼지 소속함수 때문에 하나의 입력 공간을 형성하는 퍼지 분할에서 퍼지 집합의 개수와 범위를 사용자에 따라 조절하기 어렵다. Neural Network House는 신경망을 이용하여 사용자가 서비스를 요청하는 경우, 외부의 상황정보를 학습한다. 이 경우 새로운 학습 데이터가 추가되면, 학습을 다시 해야 하는 경우가 발생한다. 이들 대부분은 사전에 정의된 정보를 사용하여 학습하기 때문에 다양한 환경에 적용하기 어렵다는 문제점을 갖는다. 이러한 문제를 해결하기 위해 비교사 학습(unsupervised learning)을 이용한 경우와 강화학습을 이용한 연구가 있다. 비교사 학습을 이용한 경우는 특징 추출, 분류(classification) 등의 학습 방법을 통하여 사용자 상황정보를 인식한다. Krause는 체온 등의 생리학, 음성, 움직임 행동(Activity), 위치, 그리고 스케줄의 다양한 상황정보를 비교사 학습을 통하여 학습한다<sup>[6]</sup>. 강화학습은

사용자의 사전정보 혹은 추천 대상에 대한 구체적인 세부정보가 필요 없이 사용자와의 상호작용만으로 학습이 가능하다라는 장점을 갖는다. 강화학습을 추천에 이용한 대표적인 연구로는 [15-18]이 있다. 이들 대부분은 전자상거래 응용에 적용된 경우이지만, Feki는 사용자 행동을 학습하여 로봇의 추천 시스템에 적용한 경우로 퍼지 기반 Q-학습(Learning)을 제안하는데, 사전에 정의된 상태만 추천에 사용된다<sup>[18]</sup>.

### III. 상황정보 기반 사용자 프로파일

본 절에서는 개인화 서비스를 제공하기 위하여 상황정보와 사용자의 서비스 사용 이력을 바탕으로 생성되는 상황정보 기반 사용자 프로파일의 기본 개념과 프로파일을 학습하기 위한 알고리즘 및 추천 알고리즘을 설명한다.

#### 3.1 기본 개념

사용자 프로파일은 상황에 적합한 개인화 서비스를 추천할 때, 판단기준이 되는 사용자 모델이다. 기존의 대표적인 개인화 기법인 내용기반 추천과 협업 추천의 경우, 앞서 설명했듯이 사용자에 대한 사전 정보로 사용자 프로파일을 구성하고 추천 아이템에 대한 세부 정보가 필요하기 때문에, 현실적으로 실제 사용자에게 적용하기 어렵다. 이러한 문제를 해결하기 위하여 본 논문은 강화학습의 기본 개념을 활용하여 사용자에 대한 사전 정보 혹은 추천 대상에 대한 구체적인 세부정보의 필요 없이 상황정보와 사용자의 서비스 사용 정보를 이용해서 학습하는 사용자 프로파일을 제안한다. 단, 사용자의 서비스 이용 정보도 프라이버시 문제가 존재하기는 하지만 허락한 사용자에 한해서 시스템에서 이용할 수 있는 정보라고 가정한다.

어떤 시간에서 앞의 행동에서 얻은 보상값(Reward,  $R_{(t)}$ ), 현재 시간에 관측된 상태(State,  $S_{(t)}$ ), 다음 시간에서 취하게 되는 행동(Action,  $A_{(t+1)}$ ), 다음 시간에 얻게 되는 보상 값( $R_{(t+1)}$ )의 구성요소가 있다고 할 때, 강화학습에서 에이전트는 다음 식과 같이 학습한다<sup>[19]</sup>.

$$R_0 + \alpha R_1 + \alpha^2 R_2 + \dots = \sum_{k=0}^{\infty} \alpha^k R_{t+k+1}$$

이때,  $\alpha$ 은 감소율(discount rate)이고  $0 \leq \alpha \leq 1$ 의 값을 갖는다. 사용자는 어떤 행동을 수행하고 그 행동에 대한 보상 값으로  $R(t)$ 를 받는다. 이 알

고리즘을 통해서 강화 학습은 결국 상태와 행동을 사상시키는 최적의 정책을 구성한다.

Feki는 강화학습의 일종인 Q-학습을 이용하여 사용자 서비스 이용 패턴을 학습하여 특정 상황에 적합한 사용자 서비스를 추천한다<sup>[18]</sup>. 이때, Feki는 퍼지 함수를 이용하여, 상황정보와 서비스에 대한 사전 클러스터링 작업이 필요하고, 고정된 상황정보에 대해서만 서비스 선택이 가능하다. 따라서 제안된 사용자 프로파일의 학습 알고리즘은 다양한 환경에 적용을 용이하게 하기 위하여 기존의 강화학습을 다음과 같이 수정하여 개선하였다. 첫째, 사용자 프로파일을 상황정보-서비스의 이차원 정보로 정의하고 상태와 현재 상태의 두 가지 개념을 분리한다. 상태는 모든 사용자 프로파일에 정의된 모든 상황정보의 합으로 구성되고, 현재 상태는 현재 사용자가 처한 환경에서 액세스 가능한 상황정보로 구성된 것으로 상태의 부분집합이다. 둘째, 사용자에게 추천을 위한 예측(prediction) 단계에서, 현재 상태를 구성하는 상황정보를 입력 받고 사용자 프로파일을 통하여 선호할 만한 서비스 리스트를 출력한다. 마지막으로, 상황정보-서비스의 값은 사용자가 특정 상황에서 서비스를 선택하거나, 서비스 추천 시 긍정 혹은 부정의 피드백에 따른 보상 값을 의해 갱신되는 데 환경에 따른 보상값 설정이 가능하다.

그림 1은 제안된 사용자 프로파일을 적용하여 학습 및 서비스 추천을 위한 시스템 구조를 나타낸다. 시스템은 학습기(Learner), 추천기(Recommender), 그리고 사용자 프로파일의 3가지로 구성된다. 학습기는 상황정보 프로파일을 가지고 [상황정보]-[서비스]의 이차원 배열을 갖는 사용자 프로파일을 구성하고, 사용자 서비스 이용 이력과 상황정보를 학습

하는 역할을 한다. 추천기는 현재 사용자 상태를 입력 받아 사용자 프로파일에 따라 사용자가 선호할 만한 서비스를 추천하는 역할을 한다. 본 시스템은 상황에 따른 사용자의 서비스 사용 히스토리 정보를 학습하여 사용자 프로파일을 만들고, 특정 상황에서 사용자의 프로파일을 바탕으로 선호 서비스를 예측하여 사용자에게 추천한다. 이를 위해 상황정보 기반 사용자 프로파일 테이블 (C-TBL)과 예측 정보 테이블 (P-TBL)을 갖는다.

### 3.2 학습기 (Learner) 알고리즘

학습기는 상황정보 프로파일을 이용하여 C-TBL을 구성하고 사용자의 서비스 사용 정보와 상황정보를 가지고 학습하는 역할을 담당한다. 서비스 사용 히스토리로부터 사용자가 선택한 서비스와 상황정보의 보상 값을 C-TBL에 반영한다. 학습기는 강화 학습의 대표적인 학습 알고리즘인 Q-학습을 이용하여 C-TBL을 갱신한다.

Q-학습에서  $Q(s,a)$ 는 상태  $s$ 에서 행동  $a$ 를 선택하는 것이 어느 정도 가치 있는지 평가해준다. 상태  $s$ 에서  $a'$ 를 선택하고, 보상 값  $R$ 을 받고 상태  $s'$ 로 전이하는 경우,  $Q(s,a)$ 는 식 (1)과 같이 갱신된다.

$$Q(s,a) \leftarrow Q(s,a) + \alpha [R + \gamma \max_a Q(s',a') - Q(s,a)] \quad (1)$$

기존 Q-학습은 현재 상태  $s$ 에서 행동의 선택에 따라 다음 상태가 결정된다. 하지만, 본 논문에서 제시되는 사용자 프로파일에서 행동은 사용자가 선택한 서비스에 해당하고, 선택된 서비스가 다음 상태를 결정하는데 연관성이 없기 때문에, Q-학습을 다음과 같이 수정한다.

$$Q(s,a) \leftarrow Q(s,a) + \alpha R \quad (2)$$

Q-학습을 C-TBL의 갱신에 사용하기 위해  $s$ 를 상황정보,  $a$ 를 서비스로 정의한다. 또한, 시스템과 사용자간 상호작용에 의한 보상 값  $R$ 을 사용자 행위에 의존하여 다음과 같이 3가지로 구분하여 정의한다. 첫째, 사용자가 명시적으로 해당 서비스를 선택한 경우이다. 이때, 보상 값을  $r_s$ 로 정의한다. 둘째, 사용자에게 시스템이 특정 서비스를 추천하고 사용자가 해당 서비스에 긍정적인 반응을 보이는 경우이다. 이때, 보상 값을  $r_p$ 로 정의한다. 마지막으로 사용자에게 시스템이 특정 서비스를 추천하고 사용자가 해당 서비스에 부정적인 반응을 보이는

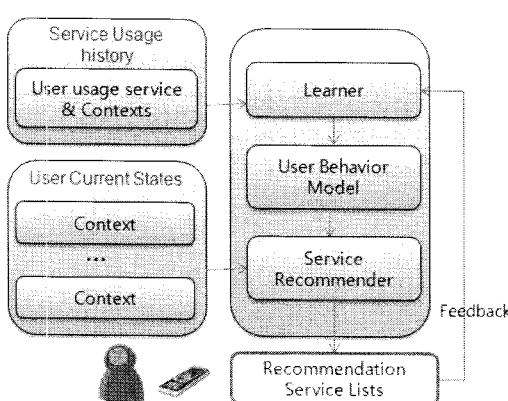


그림 1. 전체 시스템 구조

표 1. 사용자 모델 학습을 위한 상황정보 프로파일 자료구조

States = { $c_1, \dots, c_n$ },  $1 \leq n$ ,  
 $c_k$ :  $k^{\text{th}}$  context in the States  
Attributes( $c_i$ ) = { $a_{i,1}, \dots, a_{i,k}$ },  $1 \leq k$  and  $1 \leq i \leq n$   
Action Classes = { $ac_1, \dots, ac_m$ },  $1 \leq m$   
Reward R = {Selection- $r_s$ , Positive Feedback - $r_p$ , Negative Feedback - $r_n$ }

경우이다. 이때, 보상 값은  $r_n$ 으로 정의한다. 따라서 변경된 Q-학습 식 (2)는 C-TBL에 다음과 같이 적용된다.

$$C\text{-TBL}(c,a) \leftarrow C\text{-TBL}(c,a) + \alpha R, R \in \{r_s, r_p, r_n\} \quad (3)$$

사용자 프로파일을 학습하기 위해서는 상황정보가 가지는 값들에 대한 정보가 필요하다. 이 정보를 상황정보 프로파일이라 정의한다. 상황정보 프로파일의 내용을 표 1에 나타낸다.

Attributes( $c_i$ )는 상황정보  $c_i$ 가 가지는 속성값이고, 이산값을 가지는 경우와 연속 값을 가지는 경우로 구분된다. 다음 표 2는 사용자 액티비티(activity), 장소(location), 시간 상황정보 값에 대한 속성값을 표현한 것이다. 액티비티와 장소의 경우는 이산값을 가지는 경우에 해당되고 시간의 경우는 연속적인 데이터를 표현한 것으로 최소값, 최대값을 속성 값으로 갖는다. 온도, 습도 등의 연속값으로 표현되는 환경정보는 이산값으로 맵핑하기 위한 정규화가 필요하다. 실제 성능 향상을 위해서는 효과적인 정규화가 방법이 필요하지만 본 논문은 사용자 프로파일 방법의 제시에만 중점을 두어, 일반적으로 사용하는 min-max 정규화를 사용한다.

C-TBL은 각 상황정보마다 하나씩 구성되고 식 (3)을 사용하여 생성된다. 표 2와 같이 상태가 3가

표 2. 상황정보 프로파일의 예

- States = Location, Activity, Time
- Action Class = Watch TV, Listen Music, Listen News, Play Game
- Attributes(Location) = Outdoor, Living Room, Bed Room, Kitchen
- Attributes(Activity) = Wakeup, Sleeping, Showing, Cooking, Working
- Attributes(Time) = 1, 24
- Reward R = { 1.0, -1.0, +1.0 }

지 상황정보로 구성되고, 사용자가 아침 7:00( $c_3$ )에 일어나서( $c_2$ :Wakeup) 침실( $c_1$ :BedRoom)에서 뉴스 서비스( $ac_1$ :ListeningNews)를 요청하였다고 가정하자, 그러면, C-TBL[ $c_1$ ][ $ac_1$ ]과 C-TBL[ $c_2$ ][ $ac_1$ ]를 생성한다. 그리고 시간 상황정보( $c_3$ )는 min-max 정규화를 통해 해당되는 C-TBL[ $n(c_3)$ ][ $ac_1$ ]를 변경한다. 다음은 세부 학습 알고리즘을 나타낸다.

표 3. 사용자 프로파일 생성을 위한 학습 알고리즘

Step 1 If C-TBL for  $c_k$  ( $c_k \in \text{States}$ ) doesn't exist, create C-TBL for context  $c_k$  using context profiles. The context profile is required to register attribute values which each context has. Refer context profile information in the Table 1.

Step 2 is initialization phase for new context  $c_k$ . Initialize new C-TBL for  $c_k$ , set 0 to  $C\text{-TBL}[a_{k,i}][ac_j]$ , for each  $a_{k,i} \in \text{Attributes}(c_k)$ ,  $ac_j \in \text{Action Classes}$ . Initialize value of R for  $R \in \{r_s, r_p, r_n\}$ .

Step 3 repeats the following steps.

Step 3-1: Input current situation  $s(t)$ ,  $s(t)$  is consisted of sum of  $a_{k,i}(t)$ , where  $a_{k,i}(t) \in \text{Attributes}(c_k)$  and  $k \in \{1, \dots, n\}$ . The relationship among state, current state and current situation is as follows:

$$\forall c_k, c_k \in \text{Current States} \Rightarrow c_k \in \text{States}$$

Situation( $s(t)$ ,  $x$ )  $\Leftrightarrow \forall x, x \in \text{Attribute } (c_k)$ , and  $c_k \in \text{Current States}$

Step 3-2: if  $a_{k,i}(t)$  is continuous value, min-max normalization performs a linear transformation on the original data. Suppose that  $\min_a$  and  $\max_a$  are the minimum and the maximum values of  $a_{k,i}(t)$ .

$$a'_{k,i} = \frac{a_{k,i} - \min_a}{\max_a - \min_a} (\text{new\_max}_a - \text{new\_min}_a) + \text{new\_min}_a$$

Step3-3: Input an current action  $act(t)$  by user selection. Determine  $R(t)$  according to user behavior information. Update the C-TBL as following rules:

for each  $c_k$  in  $C\text{-TBL}[a_{k,i}(t)][ac(t)]$  do  
 $C\text{-TBL}[a_{k,i}][ac(t)] \leftarrow C\text{-TBL}[a_{k,i}][ac(t)] + \alpha R(t)$ ,  
where  $\alpha$  is the discount factor and  $c_k \in \text{States}$ .

### 3.3 추천기(Recommender) 알고리즘

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 선호도 값을 갖는다. 현재 상태  $s(t)$ 를 (current situation)라고 하면,  $a_i \in cs$ 이고 P-TBL은 다음 식 (4)와 같이 계산된다.

$$P-TBL[ac_k] = M(cs) \sum_{a_i \in cs} w_i \times C-TBL[a_i][ac_k] \quad (4)$$

C-TBL을 이용하여 P-TBL을 구성할 때, 각 값을 0~1 사이의 값을 갖도록 정규화하기 위한 값  $M(cs)$ 는 다음 식으로 얻어진다.

$$M(cs) = \frac{C-TBL[a_i][ac_k]}{\sum_{ac_k \in Action\ Classes} C-TBL[a_i][ac_k]} \quad (4)$$

, where  $a_i \in Attributes(C_i)$

식 (4)의  $w_i$ 는  $c_i$ 에 대한 사용자 별 가중치를 나타낸다. 일반적으로 동일한  $w_i$  값을 설정할 수 있지만 사용자의 특성에 따른 각 상황정보의 중요도를 달리하기 위해서 정보 이득에 의해 상황정보의 엔트로피를 계산한다<sup>[20]</sup>.

$$Entropy(S) = \sum_{I \in Action\ Class} [-p(I) \log_2 p(I)]$$

$p(I)$ 는  $S$ 에서 클래스  $I$ 에 속할 비율을 의미한다. 표2에 따르면, 클래스는 Watch TV, Listen Music, Listen News 그리고 Play Game가 된다.  $S$ 가  $ac_1$ 과  $ac_2$ 의 두 개의 클래스로 구성되는 집합이 있을 때, 집합 내의 모든 개체 수에 대한  $ac_1$  클래스에 속하는 개체 수의 비율을  $p(ac_1)$ 이라고 하자. 마찬가지로  $ac_2$  클래스에 대한  $p(ac_2)$ 가 있다. 그러면 엔트로피는  $-p(ac_1)\log_2(p(ac_1))-p(ac_2)\log_2(p(ac_2))$ 에 의해 계산된다. 계산된 엔트로피를 가지고 특정 상황 정보에 대한 정보 이득 값을 구하기 위한 식은 다음과 같다.  $Gain(c_k)$ 는 상황정보  $c_k$ 에 대한 정보이득 값이다.  $S_v$ 는  $c_k$ 가 가질 수 있는 모든 속성에 대한 값을 나타낸다. 계산된 상황정보들의 정보 이득 값을 각 상황정보가 갖는 가중치( $w_k$ )에 적용한다. 또한, 상황정보가 많을 경우에는 정보 이득 값에 근거하여 상황정보의 중요도에 대한 순위를 매길 수

있으며, 서비스 선택에 영향을 미치는 상황정보를 선택할 수 있게 된다.

$$w_k \approx Gain(c_k) = Entropy(s) - \sum_{v \in Attributes(c_k)} [(\frac{|S_v|}{|S|}) Entropy(S_v)]$$

마지막으로 사용자에게 추천할 서비스는 다음과 같이 결정한다. 다음 식과 같이 현재 상태에서 각 서비스(행동 클래스)  $ac$ 에 대한 값을 식 (4)를 사용하여 계산한다. 그 후 가장 큰 값을 가지는 서비스  $ac = (\text{Max}_{ac}(P-TBL[ac]))$ 를 사용자에게 추천하거나, P-TBL[ac]값의 순서를 매겨 선호 서비스 목록을 제공한다. 추천한 서비스에 대한 사용자 피드백이 있는 경우, 사용자의 반응이 긍정적/부정적이거나에 따라 학습기에 보상값  $r_p, r_n$ 로 반영할 수 있다. 하지만, 사용자로부터 피드백을 받기 위한 구체적인 방법은 서비스 제공자 혹은 응용프로그램에서 제공한다고 가정하고 본 논문에서는 구체적으로 피드백을 받는 방법은 제시하지 않는다. 다만, 추천한 서비스를 사용자가 선택한 경우는 긍정적인 경우로 보고 보상값  $r_p$ 를 C-TBL에 반영할 수 있을 것이다.

### 3.4 제안된 사용자 프로파일의 오버헤드 분석

본 절에서는 상황정보-서비스로 구성된 C-TBL의 저장하기 위한 오버헤드를 분석한다. 오버헤드에 영향을 주는 요소로는 상태를 구성하는 상황정보 수, 각 상황정보 당 애트리뷰트 수, 그리고 서비스 수이다. 예를 들면, 상황정보 수가, #C이고, 각 상황정보가 갖는 애트리뷰트 수를 동일하게 #A, 서비스 수를 #S로 가정하자. 여기서 실제 저장하기 위해 필요한 공간은 배제하고, 사용자 당, 서비스 선호도를 저장하기 위한 프로파일은 #Cx#Ax#S 만큼의 가상 공간이 필요하다. 이때, 사용자 수를 #U라고 가정하면, #Ux#Cx#Ax#S 공간상의 오버헤드를 갖는다. 따라서 제안된 사용자 프로파일이 갖는 오버헤드는 사용자 수, 상황정보 수, 애트리뷰트 수, 그리고 서비스 수에 비례하여 증가함으로 다소 큰 저장 공간을 필요로 한다. 하지만, 사용자 수, 상황정보 수, 애트리뷰트 수, 그리고 서비스 수에 따라 필요한 저장 공간을 예측할 수 있기 때문에 효율적인 사용이 가능하다고 판단된다. 또한 개인 휴대 단말에는 자신의 프로파일만 저장한다고 가정하면 비교적 적은 저장공간에 대한 오버헤드를 갖는다.

## IV. 실험

본 논문에서 제안한 사용자 프로파일을 구성하기 위한 학습기와 추천기의 성능을 유비쿼터스 컴퓨팅 환경에서 실제 사용자를 대상으로 학습하고 평가해야 하지만, 사용자 행동 정보 수집 등에서 보안과 개인의 프라이버시 문제가 해결되지 않은 상황에서는 실험하기 어렵다는 문제점을 갖는다. Keskustalo<sup>[21]</sup>는 실제 사용자를 가지고 실험하는 것은 많은 시간과 비용이 드는 작업임을 지적하였다. 따라서 본 논문에서는 모의실험을 통해 제시된 알고리즘의 성능을 평가한다. 모의실험은 UCI repository<sup>[22]</sup>에서 선택한 데이터(Create Approval, Balance)를 사용한다. 그리고 제시된 사용자 프로파일의 알고리즘과 비교할 알고리즘은 [23]를 참조하여 J48, ZeroR, 그리고 NaiveBayes로 선정하였다. 이들 알고리즘은 Weka tool-kit<sup>[24]</sup>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 경우는 절대 다수(majority) 클래스를, 연속 데이터인 경우는 평균 클래스를 선택한다<sup>[25]</sup>.

본 실험에서 사용하는 성능평가 지수는 정확도(Precision)이다. R은 사용자에게 추천되는 개수이고 RP(Recommended Preference)는 사용자가 실제 선호한 개수라고 할 때 정확도는 RP/P로 계산하여 % 값으로 나타낸다. 즉, 정확도는 추천된 항목들 중에 사용자가 선호하는 항목들의 비율을 의미한다. 신뢰성 있는 모의 실험결과를 얻기 위하여 k-fold cross validation을 적용하여 10회( $k=10$ ) 실험한 결과의 평균값을 측정한다.

먼저, 실험을 위해 상황정보 프로파일을 정의한다. *createapprovalUCIdata*의 경우, 15개의 상황정보와 9개의 이산 데이터로 구성된 것으로 정의하고 추천대상이 되는 서비스(action class)는 3개이다. 상황정보 프로파일의 정의는 앞서 설명한 표 2를 참조한다. 이러한 맥락에서 표 4는 각 데이터에 대한 인스턴스 수와 상황정보 수 그리고 각 상황정보가 이산 데이터를 가지는 상황정보 수를 나타낸다. 예를 들면, *balance*데이터의 경우 625의 인스턴스로 구성되고, 네 개의 상황정보가 모두 이산 값으로 구성된 경우를 의미한다.

표 4. 시뮬레이션을 위한 데이터 구성 예

Data	Instance	Context (discrete)	Action Class
Create Approval	665	15(9)	2
Balance	625	4(4)	3

본 논문에서는 식 (4)의 상황정보의 기중치  $w_i$ 를 조정하는 경우와 고정한 경우의 두 가지 알고리즘을 구현한다. 본 논문에서 제안한 상황인식 기반 사용자 프로파일 (CUP: Context based User Profile)로 정의한다. 따라서 CUP-A는 상황정보의 기중치를 정보이득을 통하여 조정하는 경우에 해당하고, CUP-S는 기중치를 고정한 경우로 모든 상황정보가 식 (4)에서 동일한  $w_i$ 값을 갖는다. 실험의 단순화를 위하여 식 (3)에서 보상값  $r_s$ 만 사용하고 1로 고정한다. 그럼 2와 3은 모의 실험 결과를 나타낸다.

그림 2는 이산 데이터만 가지는 상황정보를 대상으로만 실험한 경우의 성능을 나타낸 것이다. *iris*, *pima*, *wine*의 경우는 이산 값을 가지는 데이터가 없기 때문에 실험에서 제외하고, *create approval*도 15개 상황정보 중 9개를 대상으로 실험하였다. *Balance*는 모두 이산 데이터 값을 가지기 때문에 제외된 상황정보가 없이 모두 학습 대상이 된다. 그림 2에서 보면, CUP는 전체적으로 다른 알고리즘에 비해 좋은 성능을 보인다. 또한, *create approval* 데이터에서는 CUP-A가 CUP-S에 비해 성능이 좋다. 구체적으로 CUP-A의 정확도는 86.8%이고, CUP-S의 정확도는 81.2%이다. 반면에, *balance*데이터에서 CUP-A의 정확도는 89.3%이고, CUP-S의 정확도는 91.1%로, CUP-S가 CUP-A에 비해 성능이 좋은 것으로 나타난다. 상황정보에 따른 기중치

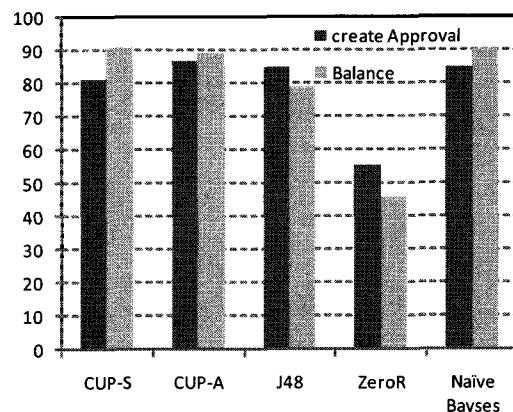


그림 2. 이산값을 가지는 데이터에 대한 실험 결과

표 5. 데이터에 따른 가중치 시뮬레이션 결과

Contexts	w <sub>i</sub> ofCreateApproval	w <sub>i</sub> ofBalance
C <sub>1</sub>	0.003	0.245
C <sub>2</sub>	0.039	0.236
C <sub>3</sub>	0.039	0.248
C <sub>4</sub>	0.136	0.272
C <sub>5</sub>	0.066	
C <sub>6</sub>	0.510	
C <sub>7</sub>	0.195	
C <sub>8</sub>	0.001	
C <sub>9</sub>	0.010	

조정이 비교적 같은 가중치 값을 갖는 경우에는 의미가 없기 때문이다. 표 5에 상황정보에 따른 가중치 값을 나타낸다. 즉, balance데이터의 경우 거의 비슷한 가중치 값을 가지므로 가중치 조절의 이점이 상쇄되고 오히려 추천 시 오류가 될 수 있음으로 판단된다.

그림 3은 연속 데이터와 이산 데이터 두 가지를 모두 가지는 데이터를 대상으로 실험한 것이다. 따라서 본 실험에서는 create approval 데이터만 해당된다. 그림 3을 보면, CUP가 ZeroR보다는 좋은 성능을 보이지만, Naïve Bayes와 J48 보다는 성능이 낮다. 그 이유는 CUP가 연속 데이터의 정규화를 위해 단순히 10개의 구간으로 분할하는 min-max normalization만 수행하였기 때문이다. 즉, 데이터의 특성을 고려하지 않고 모두 공통적인 정규화 방법을 사용하여 성능 저하를 초래하였다. 연속 데이터를 k 구간으로 분할하기 위한 휴리스틱 기법에 대한 연구가 있다<sup>[25]</sup>. 따라서 본 논문에서도 연속 데이터를 효율적인 방법으로 구간 분할할 수 있는 알고리즘에 대한 연구가 필요한 것으로 판단된다.

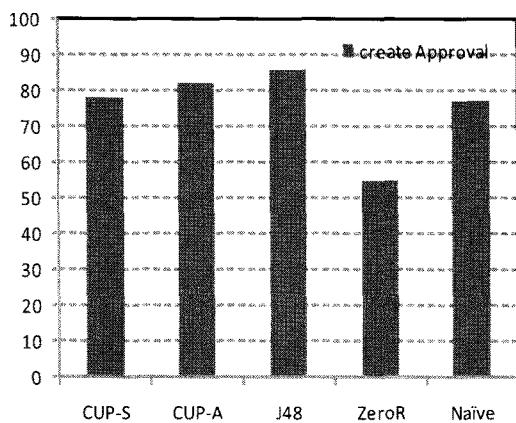


그림 3. 이산 값과 연속 값을 가지는 데이터에 대한 실험 결과

## V. 결 론

본 논문에서는 유비쿼터스 컴퓨팅 환경에서 개인화 서비스를 제공하기 위한 상황인식 사용자 프로파일 및 이를 지원하기 위한 학습 및 추천 알고리즘을 제안한다. 제안된 사용자 프로파일은 사용자와의 상호작용을 통해서 사용자 서비스 사용 패턴을 학습함으로써 사용자에게 개인화된 서비스를 능동적으로 제공할 수 있다. 학습 단계에서 [상황정보, 서비스]로 구성된 사용자 프로파일 정보를 가지고 각 상태에서 사용자의 행동에 대한 보상 값을 결정하고 학습한다. 상태 정보의 유연성을 제공하기 위해서 상태는 해당 환경 내에 설치된 센서들로부터 추출한 상황정보들로 구성하고, 액세스 가능한 상황 정보만으로 서비스를 추천한다. 추천시, 상황정보의 가중치는 정보이득을 고려하여 조절한다.

본 알고리즘의 성능을 평가하기 위하여 UCI depository에서 선택한 데이터(Create Approval, Balance)와 학습 알고리즘(J48, ZeroR, NaïveBayes)을 모의실험을 수행하였다. 주요한 결과들을 요약하면 다음과 같다. 첫째, 이산 값을 가지는 상황정보만을 대상으로 한 경우, 제안기법은 다른 알고리즘에 비해 좋은 성능을 보인다. 둘째, 정보이득을 고려한 가중치 조정은 상황정보의 특정 애트리뷰트 값이 서비스 설정에 영향을 많이 주는 경우, 즉, 상황정보 애트리뷰트 값에 따른 변별력이 클수록 의미가 있다. 마지막으로, 연속적인 데이터의 경우, 데이터의 특성을 고려하지 않은 정규화로 인하여 성능 저하를 초래한다. 따라서 향후에는 연속 데이터의 효율적인 정규화 방법 및 구간 분할 방법에 대한 연구를 진행할 계획이다.

## 참 고 문 헌

- [1] G. Adomavicius and A. Tuzhilin, "Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions," *IEEE Transaction on Knowledge and Data engineering*, 17(6), 2005, pp. 734-749.
- [2] Wireless World Research Forum, *White Paper of Service Personalization*, Ver. 1.0, 2003
- [3] 박재영 외 4인, "국외 개인화 서비스 기술 동향," TTA 저널/정보통신표준화소식, 2008.
- [4] J. Fogarty et al., "Predicting Human Interruptibility with Sensors," *ACM Trans. on Compute-Human Interaction*, 2007, pp. 1-23.

- Interaction*, 12(1), 2005, 119-146.
- [5] S. Hudson, et al., "Examining the Robustness of Sensor-based Statistical Model Human Interruptibility," *Proc. SIGCHI Conf. Human Factors in Computer Systems*, 6(1), 2004, pp. 207-214.
- [6] 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.
- [7] e-Sense, "Capturing Ambient Intelligence for Mobile Communications through Wireless Sensor Networks," *IST*, 2006.
- [8] S. Arbanowski, et al., "I-Centric Communications: Personalization, Ambient Awareness, and Adaptability for Future Mobile Services," *IEEE Communication Magazine*, 2004, pp. 63-69.
- [9] 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.
- [10] IST-2004-511607 MobiLife D27b (D4.1b) v1.0, 2004.
- [11] SPICE, Deliverable N°: 2, "Title: Specification of pro-active Service Infrastructure for Attentive Services," 2007.
- [12] 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.
- [13] H. Hagras, et al., "A Fuzzy Incremental Synchronous Learning Technique for Embedded-agents Learning and Control in Intelligent Inhabited Environments," *IEEE Conf. Fuzzy Systems*, 2002.
- [14] M. C. Mozer, "The Neural Network House: An Environment that Adapts to Its Inhabitants," *AAAI*, 1998, pp. 110 - 114.
- [15] N. Golovin and E. Rahm, "Reinforcement Learning Architecture for Web Recommendations," *Conf. in Information Technology: Coding and Computing*, 2004.
- [16] 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.
- [17] P. Rojanavasu, P. Srinil and O. Pinngern, "New Recommendation System Using Reinforcement Learning," *eBusiness*, 2005.
- [18] M. Feki, S. Lee, Z. Bien and M. Mokhtai, "Context Aware Life Pattern Prediction Using Fuzzy-State Q-Learning," *LNCS4541*, 2007, pp.185-195.
- [19] L. Kaelbling, M. Littman and A. Moore, "Reinforcement Learning: A Survey," *Journal of Artificial Intelligence Research*, vol. 4, 1996, pp. 237-285.
- [20] T. Mitchell, *MachineLearning*, McGraw-Hill, 1997.
- [21] H. Keskkustalo, Kalervo and A. Prikola, "The Effects of Relevance Feedback Quality and Quantity in Interactive Relevance Feedback: A Simulation Based on User Modeling", *LNCS3936*, 2006, pp. 191-204.
- [22] <http://archive.ics.uci.edu/ml/>
- [23] S. Louis, A. Shankar, "Context Learning Can Improve User Interaction, Information Reuse and Integration," *IEEE conf. IRI* 2004, pp. 115-120.
- [24] <http://www.cs.waikato.ac.nz/ml/weka/>
- [25] K. Jearanaitanakij and O. Pinngern, "An Information Gain Technique for Acceleration of Convergence of Artificial Neural Networks," *Conf. Information, Communications and Signal Processing*, 2005, pp.349-352.

문애경 (Aekyung Moon)



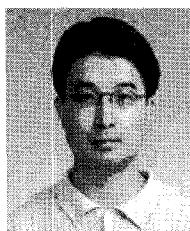
정희원

1992년 영남대학교 전자공학과  
졸업 (공학 학사)  
1997년 영남대학교 전자공학과  
졸업 (공학 석사)  
2000년 영남대학교 전자공학과  
졸업 (공학 박사)  
2000년~현재 한국전자통신연구원

원융합기술연구부문 선임연구원

<관심분야> 분산/병렬 데이터베이스, 메시징시스템,  
개인화 기술

김 형 환 (Hyunghwan Kim)

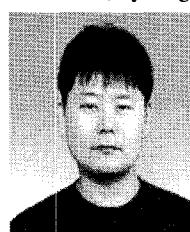


정회원

1991년 한양대학교 전자공학과  
졸업 (공학 학사)  
2000년 충남대학교 컴퓨터과학  
과 졸업 (이학 석사)  
1991년~현재 한국전자통신연구  
원 SW 서비스연구팀 책임연  
구원

<관심분야> 개방형 서비스 기술, 차세대 네트워크,  
실시간 시스템, 임베디드 시스템

박 주 영 (Juyoung Park)



종신회원

1995년 충남대학교 전자공학과  
졸업 (공학 학사)  
1997년 충남대학교 전자공학과  
졸업 (공학 석사)  
2001년 충남대학교 전자공학과  
졸업 (공학 박사)  
2001년~현재 한국전자통신연구

원 융합기술연구부문 선임연구원

<주관심분야> 멀티캐스트, QoS, 차세대 네트워크

최 영 일 (Young-il Choi)

정회원



1983년 2월 서울대학교 전자공  
학과 졸업  
1998년 2월 충남대학교 컴퓨터  
과학과 졸업 (이학석사)  
2002년 3월 충남대학교 컴퓨터  
과학과 박사  
1996년 정보통신기술사

1985년~1986년 Bell 연구소 연구원

1983년~현재 한국전자통신연구원 융합기술연구부문  
책임연구원

<관심분야> NGN, 차세대 통신서비스