

## Context Prediction Using Right and Wrong Patterns to Improve Sequential Matching Performance for More Accurate Dynamic Context-Aware Recommendation\*

Ohbyung Kwon\*\*

Developing an agile recommender system for nomadic users has been regarded as a promising application in mobile and ubiquitous settings. To increase the quality of personalized recommendation in terms of accuracy and elapsed time, estimating future context of the user in a correct way is highly crucial. Traditionally, time series analysis and Makovian process have been adopted for such forecasting. However, these methods are not adequate in predicting context data, only because most of context data are represented as nominal scale. To resolve these limitations, the alignment-prediction algorithm has been suggested for context prediction, especially for future context from the low-level context. Recently, an ontological approach has been proposed for guided context prediction without context history. However, due to variety of context information, acquiring sufficient context prediction knowledge a priori is not easy in most of service domains.

Hence, the purpose of this paper is to propose a novel context prediction methodology, which does not require a priori knowledge, and to increase accuracy and decrease elapsed time for service response. To do so, we have newly developed pattern-based context prediction approach. First of all, a set of individual rules is derived from each context attribute using context history. Then a pattern consisted of results from reasoning individual rules, is developed for pattern learning. If at least one context property matches, say  $R$ , then regard the pattern as right. If the pattern is new, add right pattern, set the value of mismatched properties = 0, freq = 1 and  $w(R, 1)$ . Otherwise, increase the frequency of the matched right pattern by 1 and then set  $w(R, \text{freq})$ . After finishing training, if the frequency is greater than a threshold value, then save the right pattern in knowledge base.

On the other hand, if at least one context property matches, say  $W$ , then regard the pattern as wrong. If the pattern is new, modify the result into wrong answer, add right pattern, and set frequency to 1 and

---

\* This research is supported by the Ubiquitous Computing and Network(UCN) Project, Knowledge and Economy Frontier R&D Program of the Ministry of Knowledge Economy(MKE) in Korea and a result of subproject UCN 09C1-T2-10M, and also supported by a grant from the Kyung Hee University in 2009.

\*\* Professor at College of Business Kyung Hee University

$w(W, 1)$ . Or, increase the matched wrong pattern's frequency by 1 and then set  $w(W, \text{freq})$ . After finishing training, if the frequency value is greater than a threshold level, then save the wrong pattern on the knowledge basis. Then, context prediction is performed with combinatorial rules as follows: first, identify current context. Second, find matched patterns from right patterns. If there is no pattern matched, then find a matching pattern from wrong patterns. If a matching pattern is not found, then choose one context property whose predictability is higher than that of any other properties.

To show the feasibility of the methodology proposed in this paper, we collected actual context history from the travelers who had visited the largest amusement park in Korea. As a result, 400 context records were collected in 2009. Then we randomly selected 70% of the records as training data. The rest were selected as testing data.

To examine the performance of the methodology, prediction accuracy and elapsed time were chosen as measures. We compared the performance with case-based reasoning and voting methods. Through a simulation test, we conclude that our methodology is clearly better than CBR and voting methods in terms of accuracy and elapsed time. This shows that the methodology is relatively valid and scalable.

As a second round of the experiment, we compared a full model to a partial model. A full model indicates that right and wrong patterns are used for reasoning the future context. On the other hand, a partial model means that the reasoning is performed only with right patterns, which is generally adopted in the legacy alignment-prediction method. It turned out that a full model is better than a partial model in terms of the accuracy while partial model is better when considering elapsed time.

As a last experiment, we took into our consideration potential privacy problems that might arise among the users. To mediate such concern, we excluded such context properties as date of tour and user profiles such as gender and age. The outcome shows that preserving privacy is endurable.

Contributions of this paper are as follows: First, academically, we have improved sequential matching methods to predict accuracy and service time by considering individual rules of each context property and learning from wrong patterns. Second, the proposed method is found to be quite effective for privacy preserving applications, which are frequently required by B2C context-aware services; the privacy preserving system applying the proposed method successfully can also decrease elapsed time. Hence, the method is very practical in establishing privacy preserving context-aware services.

Our future research issues taking into account some limitations in this paper can be summarized as follows. First, user acceptance or usability will be tested with actual users in order to prove the value of the prototype system. Second, we will apply the proposed method to more general application domains as this paper focused on tourism in amusement park.

**Keywords :** Recommender Systems, Context-Aware Service, Context Prediction, Rule Generation

# 보다 정확한 동적 상황인식 추천을 위해 정확 및 오류 패턴을 활용하여 순차적 매칭 성능이 개선된 상황 예측 방법

권 오 병

## I. 서 론

상황 기반 서비스의 대표적인 분야는 추천 서비스이다. 상황 기반의 추천 서비스는 사용자의 내외부적 상황을 자동적으로 습득한 후에 그 상황 정보를 포함하여 추천 내용의 개인화를 가능하게 하는 서비스로 상황을 고려하지 않은 기존의 추천 서비스에 비하여 개인화의 민감성과 시의적절성을 극대화하여 추천의 질을 향상시키려는 목적을 가진다.

상황 기반 추천 서비스의 성공은 현재의 상황 정보를 기반으로 미래의 발생 가능한 사용자 상황을 정확하게 예측하여 그 상황에 맞는 개인화된 서비스를 얼마나 정확하고 선응적(proactive)으로 제공하느냐에 달려있다[Tennenhouse, 2000]. 이러한 상황 예측은 방법방재 분야나 의료 분야에서 위급상황이 발생하기 전에 대처를 하게 해주거나, 쇼핑 분야에서 위치 기반의 추천을 가능하게 하거나, 헬스케어 분야에서 위기 상황을 미리 예측하게 새주고, 장비 전원 관리를 쉽게 해주며, 물류나 제조에서 가까운 장래의 양상을 예측하게 해주어 최적의 의사결정을 가능하게 하는 등 매우 유용하게 활용될 수 있다[Mayrhofer, 2005; Nurmi et al., 2005]. 또한 상황예측은 사용자 의도 파악의 기본 활동으로서 의도 인지를 가능하게 한다[Kwon et al., 2005; Hong et al., 2009].

그런데 추천 시스템에서 미래 상황이라고 하는 결과값은 규범 척도인 경우도 많으므로 회귀 분석 등 기존의 예측 방법론을 그대로 적용하기 어렵다. 또한 상황 정보로부터 어떤 추천이 바람직한 지에 대한 유의한 지식을 사전에 추출하기

도 쉽지 않다. 더욱이 상황 패턴의 종류는 상황 속성의 수에 따라 지수적으로 증가할 수 있기 때문에 규칙의 완성도 높은 집합을 확보하기도 어렵다. 이와 같은 어려움 때문에 전문가에 의한 사전 규칙 획득은 매우 어렵다.

따라서 이러한 어려움을 극복하기 위해 최근 상황인식 시스템에서의 상황 예측을 위한 추론은 사례기반추론이나 인공신경망 같은 방법들이 제안될 수 있을 것이다. 하지만 상황 정보는 다음과 같은 특징들도 가진다.

둘째, 상황 정보 습득은 환경 상의 요인 등으로 일시적으로 불가능한 경우가 있다. 따라서 상황 정보에 의한 추론 시 상황 정보가 sparse matrix의 형태일 가능성을 고려해야 한다.

셋째, 상황 정보는 센서의 품질이나 환경 상의 요인 등으로 신뢰성이 상대적으로 떨어지므로 일부 값들에 오류가 발생할 수 있다.

넷째, 상황 정보의 일부는 위치나 인구동태적 자료 등 개인의 활동에 대한 기록이므로 그 정보 활용 시 사생활 침해 우려가 있다. 따라서 이용자가 원하는 경우 이에 해당하는 상황 정보를 제외하고라도 일정 수준 이상의 예측 품질을 제공할 수 있어야 한다.

위와 같은 요인들은 전체 상황 정보를 고려할 때 정확도 향상에 장애 요인으로 작용하게 되며, 이는 사례기반추론이나 인공신경망과 같은 방법을 적용할 때 정확도를 떨어뜨리거나 예측 자체를 무의미하게 만드는 요인이 될 것이다[Mayrhofer, 2005].

따라서 본 연구의 목적은 상황인식 추천 서비스에서 상황인식이 야기하는 문제점을 극복할

수 있는 새로운 추론 방법을 제안하는 것이다. 본 논문에서 제안하는 방법론의 특징은 다음과 같다. 첫째, 처음부터 상황 속성 값을 사용하여 추론하지 않고, 개별 상황 속성에 의하여 추론된 결과의 패턴으로 추론한다. 둘째, 추론에 실패한 사례에서도 실패한 결과의 추론 분포를 학습하게 한다.

본 논문의 구성은 다음과 같다. 제 II장에서는 상황 예측과 관련된 문헌연구를 실시하였다. 그리고 제 III장에서는 본 논문에서 제안하는 패턴 기반 접근법에 의한 상황 예측 및 규칙 생성 방법을 소개하였다. 제 IV장에서는 제안된 상황인식 추천 방법과 여타 방법론을 비교한 결과를 보였다. 마지막으로 제 V장과 제 VI장에서는 각각 제안된 방법론에 관한 토의 사항 및 공헌과 추가 연구 사항을 기술하였다.

## II. 문헌 연구: 상황 예측

전통적으로 예측 방법은 회귀분석과 같이 독립 변인에 해당하는 속성이 존재하는 경우와 그렇지 않아서 시계열 자료로 예측하는 두 가지 경우로 나누어서 발전되어 왔다. 그 중 Box-Jenkins의 방법은 가장 대표적인 시계열 예측 방법이다. 그런데 이러한 방법들은 통상 명목 척도가 많은 상황 자료를 독립변인이나 종속변인으로 하여 예측하기에는 부적합하다. 따라서 상황 자료에 기반한 예측 방법은 전통적인 시계열 기법을 그대로 활용하기 쉽지 않다. 그래서 전통적인 방법에서 명목 척도 값의 예측을 위해서 제안되어온 것은 Markovian model이 있다. 그러나 이는 사전에 확률 값을 정교하고 완전하게 확보하고 있어야 하는 한계점이 있다[Kaowthumrong *et al.*, 2002].

이러한 한계를 고려하여 보완적으로 활용할 수 있는 것이 Alignment-prediction이다[Sigg *et al.*, 2006; Stephan *et al.*, 2006]. Alignment-prediction 방법은 현재 관찰된 상황 시계열이 규칙 베이스에 일정 수준 이상 일치하는 것이 있는지를 검사

하고 발견하게 되면 그 규칙 베이스 상의 이후 시계열을 앞으로 일어날 예측된 시계열로 채택하는 것이다. FoxTrot 시스템은 Alignment-prediction 방법에 의한 상황 예측 시스템으로 가장 대표적인 것이다[Loeffler, 2006].

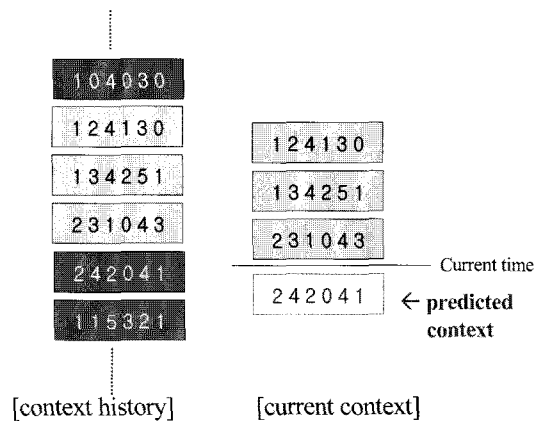
상황 예측 방법에 대한 연구는 아직 많이 진행되어 오고 있지 않으나, 다음과 같은 몇 가지 대안이 제안되고 있다. 이를 크게 나누면 현재 상황 자료만 활용하는 방법과 과거 상황 자료를 활용하는 방법으로 나눌 수 있다. 첫째로 온톨로지에 내재된 기술 논리(descriptive logic)를 활용하여 확보된 현재 상황 정보를 근거로 하여 새로운 상황 정보를 추론하는 방법이다. 이는 외부에서 상황이 발생한 후에 구동한다는 의미에서 이벤트 기반의 방식이라고도 한다. UBIWARE는 RDF 기반의 상황 정보 관련 지식을 활용하는 대표적인 시스템이다[Khriyenko and Terziyan, 2006; Projects of Industrial Ontologies Group, 2008]. 이 방법은 예측이나 추론을 위해 방대한 과거 자료를 필요로 하지 않고 현재의 상황 정보만으로도 가능하다는 장점이 있는 반면, 예측 및 추론을 위한 규칙을 사전에 정의할 수 있어야 한다는 적용상의 한계점이 있다[Mayrhofer, 2005].

둘째로 과거 상황 자료를 사용한 예측 방법이 있다. 이 방법은 필요한 과거정보를 추출, 저장하고 사용하는 이유로 시간이 많이 소요되지만 비교적 정확도를 높일 수 있는 방법으로 알려져 있다. 이때 정확도를 높이기 위해서 다양한 지능적 방법을 고려하고 있다. 그 대표적인 것으로 Bayesian Networks 알고리즘이나 트리 구조에 의한 추측 알고리즘과 같은 지능형 방법을 사용하여 상황을 예측하는 것이다. 특히 Bayesian Networks 알고리즘은 상황 정보간의 인과관계를 설명하는 설명력의 부분에 있어서는 탁월한 것으로 알려져 있다. 하지만 Bayesian Networks 알고리즘은 시간이나 위치와 같은 연속적인 값을 통한 예측에는 취약하다. 이런 예측 알고리즘들을 상황인지 서비스 구현에 적용하기에는 실제 구현의 어

려움과 실시간 환경에서 트레이닝 데이터 처리에서 오는 시간 지연 문제 등이 발생한다. 더욱이 예측을 위해 상황 속성을 복수 개 사용할 경우 사전에 인과관계를 발견하지 못할 경우 숨겨진 인과관계의 효과가 모든 상황 속성에 반영되기 때문에 이로 인해 예측력을 떨어뜨릴 취약성을 가지고 있다[Terzian, 2008].

위의 같은 단점을 극복하기 위하여 매칭 알고리즘을 활용할 수 있다. 매칭은 유용한 분석 및 추론 전략으로 오랫동안 제조, 정보시스템 등 다양한 영역에서 사용해 왔다[Keutzer, 1987; Burch and Long, 1992; Krishnamoorthy and Mailhot, 1994]. 그 중에서 시간의 흐름이 개입되는 영역에서의 매칭으로 Sequential matching 알고리즘이 제안되어 왔다. Sequential matching의 전통적인 기법으로는 두 매칭 대상의 시퀀스에 대해서 회귀분석적으로 일치 정도를 파악하는 방법이 있다[Krishnamoorthy and Mailhot, 2004]. 그러나 이 방법은 여전히 비교 대상이 규범 척도 이상의 자료여야 한다는 점에서 상황 자료의 매칭에 한계를 가진다. 예를 들어서 <그림 1>과 같이 과거의 상황 벡터의 시계열 집합에서 현재 발생한 상황과 일치하는 패턴을 만나면 해당 과거 상황 시계열 집합의 그 다음 단계 상황 벡터로 예측하는 방식이다. 그런데 정확히 일치하는 상황 집합을 찾을 확률이 높지 않을 수도 있으며 처음에 고려한 속성들 중에서 일부는 매칭에 기여하지 못하는 속성들도 있을 것이다. 따라서 수정 보완된 패턴 매칭 방법으로서 상황 정보 예측 전에 예측에 대한 목표 정확도를 정한 후에 그 정확도에 따라 매칭을 위해 고려하는 속성의 수를 가변화시키는 방법이다. 이때 과거의 특정 상황과 매치되면 매치의 다음 상황 정보가 예측될 상황정보의 후보 세트(candidate set)가 되는데, 이 후보 세트 중 최고 빈도를 갖는 후보가 예측될 상황정보가 된다[Petzold et al., 2005; Son et al., 2007]. 그러나 이 방법은 매치 자체가 없을 경우 전체 예측 정확도가 감소하는 약점을 가지고 있다. 따라서

상황이 반복적으로 발생하는 성향이 높아서 일치하는 매치가 나타날 가능성이 높은 도메인에는 적합하지만 그렇지 않은 경우에는 정확도가 급격히 떨어지게 된다. 특히 상황 인식 서비스 도메인은 매칭을 할 속성들에 대한 기존 지식이 존재하지 않을 수 있기 때문에 어떤 속성이 중요하고 어떤 속성이 매칭에 기여하지 않는지, 속성들의 값의 조합이 가지는 의미가 무엇인지를 사전에 알기가 매우 어렵다.



<그림 1> Sequential matching

한편 최근의 상황 예측을 위한 연구는 GPS 위치와 같은 단일 상황 속성에서의 예측과 복합 상황 속성에서의 예측으로 나누어서 분류할 수 있다[Mäntyjärvi, 2003]. 단일 상황의 예측에서는 이전의 상황 발생이 이후의 상황에 영향을 주지 않는다는 가정 하에 Markov predictor와 같은 방법이 활용될 수 있을 것이다[Laasonen, 2004]. 복합 상황 속성을 활용한 예측의 경우에는 위에서 언급한 Sequential matching 방법이나 사례기반추론 등의 방법을 활용할 수 있을 것이다.

한편 Context history에 상황 자료를 저장하고, 이를 필터링 하여 각 상황 자료와 사용자의 분류에 따라 가장 적합한 서비스를 제공하고자 하는 연구는 이미 진행되어 왔다. 또한 사용자가 느끼는 상황 자료를 퍼지 알고리즘을 이용하여 받아들인

연구도 진행되었다[Byun and Cheverst, 2004; Van Setten *et al.*, 2004; Adomavicius *et al.*, 2005; Hong *et al.*, 2009]. 그런데 이들 연구는 상황의 추론이며 미래 시점의 예측에 맞추어져 있지 않다. 더욱이 대부분의 방법들이 성공적인 패턴으로부터의 학습에 맞추어져 있는데 이러한 방법들은 정확도에서 한계를 보이고 있다. 따라서 예측 관점에서 정확도를 향상시킬 수 있는 방법의 고안이 필요하다.

### Ⅲ. 상황 기반 추천

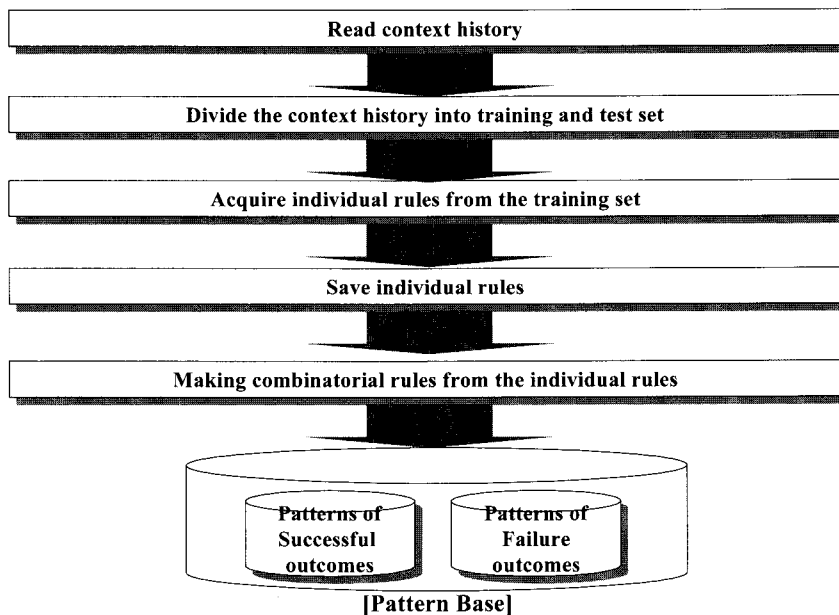
#### 3.1 상황 예측을 위한 패턴 기반 학습

본 논문에서 제안하는 상황 예측 방법의 전체적인 프로세스는 다음 <그림 2>와 같다. 먼저 과거에 발생한 상황 정보(context history)를 저장소에서 읽어온다. 이를 학습을 위한 집합과 테스트를 위한 집합으로 임의의 기준을 활용하여 나눈다. 그리고 학습을 위한 상황 집합을 활용하여 개

별 규칙(individual rules)을 생성한다. 여기서 개별 규칙이란 학습과 예측을 위해 고려하고 있는 상황 속성이 복수 개일 경우 각 상황 속성 하나에 대해서 인과관계를 규명하는 규칙을 의미한다. 각 상황 속성 별로 개별 규칙이 확정되면 그 규칙에 의하여 개별 상황 속성 별로 추론한 결과 값을 구하게 하여 하나의 예측 값 벡터를 생성하게 되는데 이때 이 벡터 값을 통하여 얻어지는 규칙이 조합 규칙(combinatorial rule)이다. 개별 규칙과 조합규칙을 작성하는 방법에 대해서는 다음에 기술하였다.

#### 3.1.1 개별규칙 생성

- Step 1(각 상황별 개별 예측 규칙 생성): 현재 확보된 학습용 상황 정보 집합  $C = \{c_{i,j}, o_i \mid i = 1, \dots, M, j = 1, \dots, N\}$ 에서  $j$ 는 임의의 상황 속성을,  $i$ 는 사례를 의미한다. 이때 각 개별 상황 속성  $j$ 에 대해서  $c_{i,j}$ 와  $o_i$  사이의 인과관계를 추정한다. 이때,  $c_{i,j}$ 와  $o_i$ 가 모두 명목 척도



<그림 2> 전체적인 학습 프로세스

인 경우에는 비율 분석을 통해서 가장 비율이 높은 값을 채택할 수 있다. 예를 들어 다음과 같이 계절(season)별로 특정 지역(site)을 방문한 기록을 요약한 표가 <표 1>과 같이 있다고 하자.

<표 1> 계절별 특정 지역 방문 기록 요약한 예제

Season( $c_{.j}$ )	Site( $o$ )	Ratio(%)
Spring	Site A	35%
Spring	Site B	28%
Spring	Site C	15%
Spring	Site D	22%

그러면 "Spring"에는 "SiteA"를 방문한 비율이 35%로 다른 방문지에 비하여 가장 크므로  $f_j : c_{.j} = \text{"Spring"} \rightarrow o_{\text{"SiteA"}}$ 가 된다. 이렇게 하면 "Season"의 모든 속성 값 별로 최빈 방문 지역을 구하게 된다.

이와 같은 수행을 통해서  $f_j : c_{.j} \rightarrow o$ 를 나타내는 N개의 인과관계를 획득한다.

- Step 2: 모든 j에 대해서 얻어진  $f_j : c_{.j} \rightarrow o$ 를 개별 규칙 베이스에 저장한다.

### 3.1.2 조합 규칙 생성

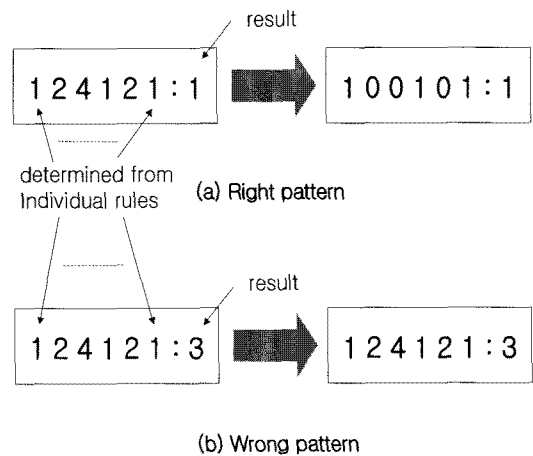
개별 규칙이 확보되면 이를 토대로 하여 다음과 같은 방법으로 조합 규칙이 생성된다.

- Step 3(조합 규칙 생성): 확보된 개별 규칙들을 통해서 학습용 상황 집합에 적용하여 추론해 본다.
- Step 3-1(정답 패턴의 경우): 이때 정확하게 추론한 속성이 하나 이상이면 정답 패턴으로 간주한다. 그리고 패턴은 <그림 3>(a)과 같이 기존 상황 벡터에서 정답에 기여한 속성의 값은 그대로 두고, 오답을 낸 속성의 값은 0으로 처리하여 차후의 의사결정에 기여할 수 없게 한다. 이때 이미 등록된 정답

패턴이면 그 패턴에 대해서 빈도수를 1 증가시키고 그에 해당하는 패턴에 대한 confidence를 나타내는  $w_s(k)$ 를 구한 후에 저장한다. 단, 여기서 k는 빈도수를 의미하며,  $w_s$ 는 정답을 맞추었을 때의 confidence 함수이다.

또한 정답 패턴으로 기억된 패턴에 대해서 오답으로 판명되면 빈도수를 1 감소시키고  $w_s(k)$ 에서 k를 1차감하여 적용한 수에 저장한다.

- Step 3-2(오답 패턴의 경우): 이때 정확하게 추론한 속성이 하나도 없으면 오답 패턴으로 간주한다. 이때 이미 등록된 오답 패턴이면 그 패턴에 대해서 빈도수를 1 증가시키고 그에 해당하는 패턴에 대한 confidence를 나타내는  $w_p(k)$ 를 구한 후에 저장한다. 패턴은 <그림 3>(b)과 같이 변경시키지 않는다. 단, 여기서 k는 빈도수를 의미하며,  $w_p$ 는 오답인 경우의 confidence 함수이다. 또한 정답 패턴에서 오답을 추론한 속성의 값은 0으로 저장한다. 또한 오답 패턴으로 기억된 패턴에 대해서 정답으로 판명되면 빈도수를 1 감소시키고  $w_p(k)$ 에서 k를 1차감하여 적용한 수에 저장한다.



<그림 3> 두 가지 패턴 집합

- Step 4(규칙 등록 판정): 학습을 종료한 후에 특정 임계치를 뜻하는  $\theta_S$ 에 대해서  $w_S(k) \geq \theta_S$ 이면 정답 패턴 지식으로 등록한다. 마찬가지로  $\theta_F$ 에 대해서  $w_F(k) \geq \theta_F$ 이면 오답 패턴 지식으로 등록한다.

### 3.2 상황 기반 추론

학습이 종료된 후에 추론에 활용할 때에는 다음과 같은 원칙을 따른다.

- Step 1: 현재 상황을 인식한다.
- Step 2: 각 상황 속성별로 개별 규칙을 활용하여 각 속성이 예측하는 예측 결과를 추론하고 그 결과로 현재 속성의 패턴을 작성한다.
- Step 3: 먼저 패턴 저장소에 저장되어 있는 정답 패턴 들 중에서 일치하는 패턴이 있는지를 검색한다. 만약 어느 하나와만 동일한 경우 해당되는 패턴을 적용하여 그 패턴이 보유하고 있는 result 값으로 추론하고 끝. 해당하는 정답 패턴이 둘 이상 존재하는 경우에는 Step 4로 이동하고 하나도 존재하지 않는 경우에는 Step 5로 이동한다
- Step 4: 만약 정답 패턴들 중에서 복수개의 패턴과 동일하고 그것이 모두 정답 패턴이라면

가장 specific 한 패턴을 따른다. 예를 들어서 문제가 <2, 2, 0, 2, 0> 이고 등록된 패턴이 <2, 0, 0, 0, 0>과 <2, 2, 0, 0, 0>이라고 하면 <2, 2, 0, 0, 0>을 적용하고 종료한다.

- Step 5: 만약 등록된 정답 패턴과 매치되는 것이 없으면 오답 패턴 중에서 일치하는 것을 검색한다. 이때 발견되었으면 그 오답 패턴에 등록된 결과값으로 추론하고 끝. 만약 오답 패턴에서도 매치되는 것이 없을 경우에는 Step 6으로 진행한다.
- Step 6: 만약 오답 패턴에서도 매치되는 것이 없을 경우에는 가장 예측력이 높았던 하나의 상황의 individual rule을 활용하여 추론 결과를 구한다.

## IV. 실험

모의실험을 위한 사례는 야외 공원에서 사람들이 현재의 방문지에서 다음에 어떠한 방문지로 이동하는지를 예측하는 것이다. 이를 위해서 한국의 대표적인 야외 공원인 에버랜드 방문자들에 대해서 그들이 에버랜드 내의 여러 사이트들을 어떤 경로로 방문했는지에 대해 설문 조사를 했다. 설문 항목으로는 먼저 비교적 변화가 심하지 않은 응답자의 인구동태적, 심리동태적인

<표 4> 실험을 위한 상황 구조

Category 1	Category 2	Context	Type
Input	Extra-personal	Current Site	String
		Season	String
		Time	1, 2, 3
	Intra-personal	Perceived Climate	7 scale
		Perceived Temperature	7 scale
		Perceived Queuing Time	7 scale
		Preference on novelty	7 scale
		Patience against waiting time	7 scale
		Gender	Binary
		Ages	1, 2, 3, 4, 5
		Result	Next Site



속성을 포함하였다. 여기에는

- 성별(X1)
- 연령대(X2)
- 신규 경험 혹은 반복 경험에 대한 선호도(X3)
- 대기 시간에 대한 민감도(X4)

등이 포함되었다. 그리고 매번 방문마다 발생하는 상황적인 속성으로는 다음과 같은 요소들을 선정하였다.

- 방문 월(C1)
  - 방문 시간대(C2)
  - 인지된 날씨(Z1)
  - 인지된 온도(Z2)
  - 인지된 평균 대기 시간(Z3)
  - 당시 방문한 사이트의 순서(Z4)
- 등이다.

이러한 질문에 대해서 2009년 2월부터 3월까지 에버랜드 출구에서 청소년 및 성인들을 대상으로 설문 조사를 실시하였으며 총 400부를 획득하였다. 이렇게 하여 획득한 400개의 응답 중에서 임의로 30%에 해당하는 120개의 자료는 테스트용으로 두고 나머지 70%인 280부에 대해서 본 방법론에 따라서 규칙을 생성하였다. 기타 시물레이션의 configuration은 다음 <표 5>와 같다.

<표 5> 시물레이션 configuration

Parameter	Value
Number of context	10
Size of context history for training	280
Size of context history for testing	120
Threshold	0, 3, 6, 9, ..., 87
Simulation runs per methods	120

성능 측정을 위하여 비교할 방법론은 다음의 아홉 가지이다.

- (1) CBR: 일반적으로 사용하는 case based reasoning. 본 연구에서는 강화된 가중치를 고려한 유클리디언 함수를 활용한 방법인 Tversky 방법을 사용했다.
- (2) CBR\_PR: 일반적으로 사용하는 case based reasoning에서 사생활 침해 우려가 있는 것을 제외한 경우이다. 이때 사생활 침해 우려가 있는 정보로는 방문 시간과 답변자의 성별 및 나이로 보았다.
- (3) CBR\_OB: 일반적으로 사용하는 case based reasoning에서 객관적으로 측정이 가능한 상황만 고려한 경우이며, 본 실험에서는 심리적인 속성인 인지된 기후 선호, 인지된 온도 선호, 인지된 대기 시간, 새로운 제안에 대한 선호도, 대기에 대한 인내의 정도들을 주관적인 상황으로 보고 제외하였다.
- (4) PARTIAL: 본 연구에서 제안하는 방법론으로 정답 패턴만을 고려한 경우
- (5) PARTIAL\_PR: 본 연구에서 제안하는 방법론으로 정답 패턴만을 고려하나 사생활 침해 우려가 있는 상황을 사용한 추론을 배제한 경우
- (6) PARTIAL\_OB: 본 연구에서 제안하는 방법론으로 정답 패턴만을 고려하나 객관적으로 측정이 가능한 상황만을 고려하여 추론한 경우
- (7) FULL: 본 연구에서 제안하는 방법론으로 정답 패턴과 오답 패턴을 모두 고려한 경우
- (8) FULL\_PR: 본 연구에서 제안하는 방법론으로 정답 패턴과 오답 패턴을 모두 고려하고 사생활 침해 우려가 있는 상황을 사용한 추론을 배제한 경우
- (9) FULL\_OB: 본 연구에서 제안하는 방법론으로 정답 패턴과 오답 패턴을 모두 고려하고 객관적으로 측정이 가능한 상황만을 고려하여 추론한 경우

위와 같은 상황 각각에 대하여 총 120회의 시물레이션을 수행하고, 각 시물레이션에서는 1,000 회씩 반복 실험을 하였다. 그리고 성과를 측정하

는 지표로는 예측 정확도(accuracy of predicted contexts)와 알고리즘 수행 소요 시간(elapsed time)을 선택하였다. 예측 정확도는 상황 예측 연구에 있어서 가장 보편적이고 중요한 성과 요소이다 [Mayrhofer, 2005],

실험 수행 결과는 <표 6>에 요약되어있다. <표 6>에 의하면 사례기반추론은 전체적으로 30~40% 수준이었으나, 본 논문에서 제안한 방법론으로 학습 및 추론한 경우 최소한 70% 이상의 성과를 보여 상세한 통계적 유의성 분석이 필요 없을 정도로 극명한 성과 간 차이를 보였다.

한편 본 논문의 제안 방법론에 대해서도 정답 패턴만 고려한 경우(partial model)와 정답, 오답 패턴을 모두 고려한 경우(full model)를 나누어서 성능 분석을 수행하였으며, partial model의 경우 70~90% 사이의 정확도를 보인 데 비해, full model의 경우 97~99%에 이르는 현격한 성과의 차

이를 보였다. 이는 오답 패턴을 같이 고려하는 것이 성과에 많은 영향을 주는 것을 보여주고 있는 것이다.

더욱이 사생활침해우려가 있는 상황 속성을 배제하고라도 우수한 결과가 나올 수 있는지를 평가해 보았다. 사생활 정보 노출에 대한 우려는 예측 정확도와 함께 중요한 성과요소를 인식되어 왔다[Mayrhofer, 2005]. 그 결과 도리어 상황 속성 모두를 사용하는 것보다 사생활 침해 우려가 있는 시간이나 성별, 나이 등과 같은 상황 속성을 제외한 것이 도리어 모든 상황 정보를 모두 고려한 경우보다 오히려 성과가 좋게 나타났다. 그러면서도 알고리즘 처리 시간은 유의할 정도로 개선되었다. 결국 사생활 우려가 있는 상황 속성을 배제하더라도 동일하거나 도리어 우수한 예측 성과를 보였다는 사실이다.

또한 Full model보다 Partial model의 학습 소

<표 6> 예측 방법 별 성능 비교

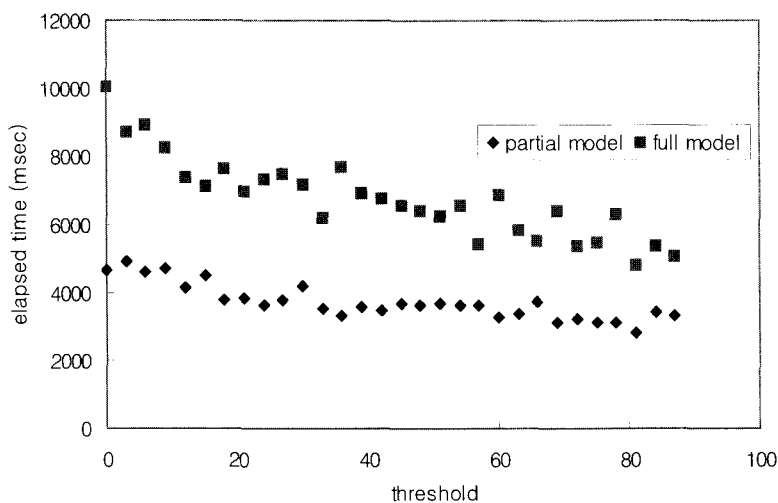
	Accuracy (%)		Elapsed time (msec)	
	Mean	Standard error	Mean	Standard error
[CBR]				
Full context	27.36	3.94	45203.03	2617.347
Excluding privacy concern data	32.97	3.86	20571.37	11763.07
Excluding subjective data	24.47	3.47	13100.03	960.89
[Voting]				
Full context	25.09	4.31	197326.00	1019.67
Excluding privacy concern data	24.39	3.24	223634.17	9636.51
Excluding subjective data	39.47	5.58	223449.09	9835.57
[Full Model]				
Full context	97.89	1.73	8329.86	1587.86
Excluding privacy concern data	98.83	1.62	6471.45	1201.69
Excluding subjective data	98.11	1.30	5665.24	1074.31
[Partial Model]				
Full context	73.26	1.40	4649.47	840.65
Excluding privacy concern data	84.18	1.17	3588.53	590.15
Excluding subjective data	73.24	1.73	2932.27	497.03

요시간이 더욱 짧았다. 이것은 오답 패턴에 대한 학습을 수행하지 않은 이유이다. 만약 실시간의 기민한 학습이 필요한 경우에는 정확도보다는 소요시간이 더 중요한 성과 요소일 수 있다. 물론 두 모델 사이의 소요시간의 차이는 약 3~4초 정도이므로 추론을 위한 규칙 생성에 있어서 그 차이는 많다고 보기 어렵고, 하드웨어의 성능이 더 우수해질수록 이 차이는 더 좁혀질 수 있다. 그러나 현재의 실험은 280개의 사례를 가지고 학습을 수행한 것이므로 실제적으로 매우 많은 사례를 통한 학습을 수행하게 된다면 이 소요시간의 차이는 중요한 요소가 될 것이다.

한편 역치와 소요시간 사이의 상관관계 유무를 파악하기 위해 먼저 테스트에 사용된 120개 데이터에 적용된 역치 별로 군집화 하여 평균 소요시간을 산포도로 전체적인 모습을 분석해 보았으며, 그 결과 <그림 4>와 같이 나타났다. 역치는 각 실험 때마다 0에서 87까지의 3이 배수 가운데서 임의로 선정하여 수행하였다. 90이상을 수행하지 않은 이유는 테스트 데이터가 전체 400개의 30%인 120개 내외인 상태에서 어떤 동일한 패턴이 전체 테스트의 75%를 상회하는 90개 이상 나오기란 확률적으로 불가능하기 때문이다.

다시 말해서 90이상으로 역치를 지정하면 사실상 모든 규칙을 참조하게 되기 때문에 역치 값을 더 높인다 하더라도 소요시간에는 변동이 없을 것이다. 실제로 테스트를 위해 사용된 상황 정보에 대해서 분석한 결과 전반적인 상관관계를 나타낸 그림4를 보면 처음에는 역치의 증가량에 따라 소요시간이 급감하는 모습을 보이다가 역치가 15 정도에서 완만해지는 모습을 관찰할 수 있다.

역치와 소요시간 사이의 정확한 상관관계 파악을 위해 회귀분석을 수행하여 보았으며 그 결과는 <표 7>과 같다. 분산분석에 의하여 Full Model의 F비는 103.0924이며 Partial Model의 경우 72.3347로 회귀분석모형은 통계적으로 유의한 것으로 보인다. 회귀분석 결과 Full Model의 경우에는 역치 1 증가마다 약 0.4초 정도의 소요시간 감소효과가 있는 것으로 보인다. 한편 <그림 4>에서 급격한 감소를 보인 초기값(0~15)에 대해서만 분석한 결과에는 통계적으로 유의하게 역치 1 증가마다 약 0.18초 정도의 소요시간 감소효과가 있는 것으로 나타났다. 한편 Partial Model의 경우에는 역치 1 증가마다 약 0.17초 정도의 소요시간 감소효과가 있는 것으로 나타났다. 한편 초기값(0~15)에 대해서만 분석한 결과에는 역치 1 증



<그림 4> 역치와 소요시간과의 상관관계

&lt;표 7&gt; 회귀분석 결과

Full Model				
[0~87]	계수	표준 오차	t 통계량	P-값
Y 절편	8521.76	201.6927	42.2512	6.60277E-27
Threshold	-40.42	3.9812	-10.1534	6.86964E-11
[0~15]	계수	표준 오차	t 통계량	P-값
Y 절편	9785.30	239.5399	40.8504	2.15E-06
Threshold	-183.65	26.3725	-6.9636	0.0022

Partial Model				
[0~87]	계수	표준 오차	t 통계량	P-값
Y 절편	4463.37	101.3233	44.0508	2.09E-27
Threshold	-17.01	2.0000	-8.5050	3.02E-09

가마다 약 0.28초 정도의 소요시간 감소효과가 있는 것으로 나타나서 Partial Model의 경우에는 초기에 두드러진 소요시간 감소효과가 있다고 보기는 어려운 것으로 판단된다.

한편 Partial Model을 적용할 경우의 소요시간은 Full Model을 적용할 경우의 소요시간보다 전 역치 구간에서 낮은 것으로 나타났다. 이것은 역치와 상관없이 Partial Model이 더 신속한 결과를 산출함을 의미하는 것이다.

## V. 토 론

### 5.1 적용 상의 시사점

본 연구의 방법론으로 실험한 결과로부터 얻은 중요한 적용상의 시사점은 상황인식 서비스의 특성에 따라 적합한 상황예측 방법론을 선정하는 것이 필요하다는 점이다. 이에 대해 보다 구체적으로 다음과 같이 언급할 수 있다.

첫째로, 적합성은 정확도와 소요시간이라고 하는 두 가지 지표의 상충관계를 고려해야 한다는 점이다. 앞서 실험에서 Partial Model을 적용할 경우의 소요시간은 Full Model을 적용할 경우의 소요시간보다 전 역치 구간에서 낮은 것으로 나

타났고, 이것은 역치와 상관없이 Partial Model이 더 신속한 결과를 산출함을 의미함을 언급한 바 있다. 따라서 정확도는 일정 수준으로 유지면 되고 소요시간을 줄이는 것이 중요한 대규모 혹은 복잡한 상황인식 서비스에는 Partial Model을 적용하는 것이 유리할 수 있다는 점을 시사한다. 실제로 상황인식 서비스는 그 종류마다 신속함과 정확도에 대한 중요도의 차이가 있다. 예를 들어 대규모 쇼핑 공간에서의 개인화 추천의 경우에는 정확도보다는 신속성이 중요하고, 원격 건강검진과 같은 헬스케어 서비스의 경우에는 정확도가 월등하게 중요하다. 따라서 대상 서비스가 그렇다면 대규모 쇼핑 공간에서의 개인화 추천을 위한 상황 예측에는 Partial Model이, 원격 건강검진인 경우에는 Full Model이 더 유리할 것이다.

둘째로, 상황인식 서비스별로 사생활 침해 우려 정도가 차이가 난다. 일반적으로 B2C형 서비스는 B2B형 서비스보다 최종 사용자인 개인의 상황 정보가 있어야 개인화가 가능하므로 사생활 침해 우려의 가능성이 더 높다. 따라서 이 경우에는 사생활 침해 관련 상황 속성을 획득하거나 제3의 용도 사용하는 것이 어려워지는데 본 논문에서 제안한 방법론은 이러한 정보를 제외하더라도 정확도면에서 열등한 결과가 나오지 않을 수

있고, 도리어 반응에까지 소요되는 시간을 줄이는 효과까지 있음을 보여서, 사생활 침해 우려에도 불구하고 사용자들이 수용할 수 있는 방법론의 하나로 판단된다. 결국 본 방법론은 privacy preserving system 구축을 위한 경쟁력 있는 대안이라고 보여진다. 하지만 본 논문에서 적용한 사례는 비록 그것이 실질적인 자료임에도 불구하고 보다 더 많은 사례에 적용해 봄으로써 효과의 일반성을 주장할 수 있어야 할 것이다.

## 5.2 실험 자료

상황 예측 방법론의 성능은 검증에 활용된 상황 자료의 신뢰성에 많이 좌우된다[Sigg *et al.*, 2007]. 특히 상황 예측 방법론에 대한 정확도의 우수성을 검증하기 위하여 사용하는 상황 집합이 센서로부터 획득되는 raw data인지, 추론에 의하여 만들어지는 추상적 상황 자료인지에 따라 성과 측정 결과는 차이가 날 수 있다. 한편 추상적 상황 자료는 raw data에 내포되어 있는 정보의 손실(information loss)이 일어날 가능성이 있고 원래의 상태로 복구도 불가능(irreversible)할 수 있기 때문에 성능 측정에 있어서 왜곡이 일어날 수 있다[Stephan *et al.*, 2006]. 또한 시계열 자료와 같은 단일 상황 속성 자료인지 아니면 다속성 자료인지에 따라서도 성과의 차이가 날 것이다. 따라서 방법론의 검증에는 검증 대상 상황의 특성에 대한 충분한 설명이 필요하다.

상황 예측의 총체적인 정확성은 상황을 습득할 당시의 어려움, 상황 해석 단계의 어려움, 그리고 상황 예측 단계의 어려움을 모두 고려하여 계산된다[Sigg *et al.*, 2007]. 그런데 본 연구에서는 사용자로부터의 설문지 법을 통한 상황 정보 습득을 하였기 때문에 상황 습득 상의 어려움은 설문 작성의 진실성에 관련된다고 볼 수 있다. 물론 불성실한 응답에 대한 설문은 제외하였으나 성실하게 응답한 경우에도 인지적 오류는 가능하므로 최종적인 정확도 검증에 이 어려움은 어느 정

도 반영되었다고 볼 수 있다. 상황 해석 단계에 발생하는 어려움은 확보된 상황 정보를 재해석하거나 재구조화함으로써 발생하는 것을 의미하는데, 본 연구에서는 시간대를 24시 기준으로 입력 받은 다음에 이것을 오전, 오후, 저녁으로 3등분한 바 있고, 그 외에는 입력 받은 값을 그대로 활용하였다. 따라서 해석 단계상의 어려움도 정확도 계산에 반영되어 있다. 결국 상황 예측의 정확성 측정에 연관되는 세 오류의 효과는 본 방법론 검증에 관한 실험에 모두 반영되었다고 볼 수 있다.

## 5.3 성능 비교 대상

그 동안 상황 자료를 추론하고, 추론된 결과를 기반으로 가장 적합한 서비스를 제공하고자 하는 연구는 꾸준히 진행되어 왔다. 특히 적합한 서비스를 제공하고자 하는 알고리즘 또한 추천 시스템 분야에서 다양하게 개발되어 있으며, 많은 연구를 통해 개발 및 적용이 되고 있음을 알 수 있다. 상황 인식적인 서비스 추천을 위해서 Classification Algorithm과 Association rule, 온톨로지 기반의 알고리즘 등이 있다. 그리고 개인화된 것을 추론하는 연구 또한 상황인지 상황에서 개발되고 있다[Si *et al.*, 2005; Doulkeridis *et al.*, 2006; Lee, 2007]. 따라서 이러한 알고리즘과 본 연구의 방법론을 성능 비교할 수 있겠다.

하지만 본 논문의 실험에서는 본 방법론이 CBR과 Voting을 혼용한 방법이기 때문에 이 혼용이 한 방법만을 사용한 경우에 비하여 뚜렷한 추가적인 성능 향상이 있는지를 파악하는데 주안점을 두었다. 그리고 기대한 이상으로 성능 향상이 뚜렷이 나왔기 때문에 두 방법은 시너지가 있음을 확인하였다. 그 외의 방법론과의 비교는 추후 연구 내용으로 두었다.

## VI. 결 론

상황 예측은 상황인식 어플리케이션의 의미

있는 확장으로 알려져 있다[Stephan *et al.*, 2006]. 즉, 상황인식 서비스 개발을 위해서 상황을 정확하게 예측하는 것은 상황 정보의 수집 빈도를 감소시켜 서비스 소요 비용을 줄이는데 중요한 역할을 한다. 이러한 역할은 수집하는 상황 정보의 종류가 늘수록 더 커지게 된다. 그 동안 각종 예측 방법들이 제안되어 왔고, 또한 성공적으로 사용되어 왔으나 상황 정보가 가지는 종류의 다양성 및 변동성, 대부분 규범 척도라는 척도의 제한성, 개인적 상황 정보 노출의 제한성, 상황 정보 처리의 신속성 요구 등 여러 가지 특성 때문에 기존 예측 방법론을 그대로 적용하기가 쉽지 않다. 또한 상황 정보 간의 인과관계는 잘 알려져 있지 않고, 알려졌다고 하더라도 도메인 내로 한정되기 때문에 일반성이 결여되어 있기 때문에 이를 사전에 파악하여 이를 고려한 예측 규칙을 전문가로부터 획득하는 것도 매우 어려운 일이다.

이러한 특성을 가진 상황 정보로 미래 상황을 예측하기 위해 본 논문에서는 각 상황 속성의 예측력을 고려한 패턴 기반의 상황 예측 방법론을 제안하였다. 이론적으로는 그 동안 지지되어 왔던 sequential matching 방법을 개선함으로써 말미암아 사례기반추론이나 투표 방법 등 경쟁 방법

론보다 정확도와 소요시간 면에서 월등하게 우수함을 보일 수 있었다. 또한 프라이버시 침해의 우려가 있는 정보를 제외하더라도 예측력에 거의 차이를 보이지 않았으며 도리어 소요시간을 감소시키는 효과도 관찰할 수 있었다. 즉, 제안된 방법론은 적용하려고 하는 서비스 대상의 특징에 따라 프라이버시 침해의 우려 정도, 서비스 반응 속도의 중요성, 요구되는 예측력 등의 기준을 고려한 매우 유연한 상황 예측 시스템을 구현할 수 있다는 점에서 실용적 시사점도 있다. 이러한 유연성의 실현은 본 방법론 내에서 규칙 등록 기준인 역치의 변경, Full Model과 Partial Model에 대한 선택, 프라이버시 우려가 있는 상황 혹은 주관적 상황의 선택적 사용이 허용 가능함에 기인한다.

추후 연구 이슈는 다음과 같다. 첫째, 상황 예측의 성능에 대한 궁극적인 측정은 사용자의 수용성 정도에 있다. 본 논문에서 소개한 프로토타입 시스템에 대해서 실제로 사용자 집단을 대상으로 실험을 진행하고 사용자 수용성에 대해 점검해야 한다. 둘째로 현재는 어뮤즈먼트 파크에만 적용하였으나 추후 상황 정보 획득이 가능한 더 다양한 도메인에도 적용하여 본 방법론의 일반성을 증명할 것이다.

## 〈References〉

- [1] Adomavicius, G., Sankaranarayanan, R., Sen, S., and Tuzhilin, A., "Incorporating contextual information in recommender systems using a multidimensional approach," *ACM Transactions on Information Systems*, Vol. 23, No. 1, 2005, pp 103-145.
- [2] Burch, J.R. and Long, D.E. "Efficient Boolean Function Matching," *International Conference on Computer Aided Design*, 1992, pp. 408-411.
- [3] Byun, H.E. and Cheverst, K., "Utilizing context history to provide dynamic adaptations," *Applied Artificial Intelligence*, Vol. 18, 2004, pp. 533-548.
- [4] Doukeridis, C., Loutas, N., and Vazirgiannis, M., "A system architecture for context-aware service discovery," *Electronic Notes in Theoretical Computer Science*, Vol. 146 No. 1, 2006, pp. 101-116.
- [5] Hong, J., Suh, E.H., Kim, J., and Kim, S.Y., "Context-aware System for proactive personalized service based on context history," *Expert Systems with Applications*, Vol. 36, No. 4, 2009, pp. 7448-7457.

- [6] Hong, J.Y., Suh, E.H., and Kim, S.J., "Context-Aware Systems: A Literature Review and Classification," *Expert Systems with Applications*, Vol. 36, No. 4, 2009, pp. 8509-8522.
- [7] Kaowthumrong, K., Lebsack, J., and Han, R., "Automated Selection of the Active Device in Interactive Multi-Device Smart Spaces," *Proceedings of the Ubicomp 2002 Workshop on Supporting Spontaneous Interaction in Ubiquitous Computing Settings*, 2002.
- [8] Keutzer, K., "DAGON: Technology Binding and Local Optimization by DAG Matching," *24th Design Automation Conference*, 1987, pp. 341-347.
- [9] Khriyenko, O. and Terziyan, V., "A Framework for Context-Sensitive Metadata Description, International Journal of Metadata," *Semantics and Ontologies*, Vol. 1, No. 2, 2006, pp. 154-164.
- [10] Krishnamoorthy, S. and Mailhot, F., "Boolean Matching of Sequential Elements," *Proceedings of the 31st Annual Conference on Design Automation*, San Diego, 1994, pp. 691-697.
- [11] Krishnamoorthy, S. and Mailhot, F., "Matching and Retrieving Sequential Patterns Under Regression," *Proceedings of the IEEE/WIC/ACM International Conference on Web Intelligence (WI 2004)*, 2004, pp. 84-90.
- [12] Kwon, O., Choi, S., Park, and G., NAMA: "A Context-Aware Multi-Agent Based Web Service Approach to Proactive Need Identification For Personalized Reminder Systems," *Expert Systems with Applications*, Vol. 29, No. 1, 2005, pp. 17-32.
- [13] Laasonen, K., Raento, M., and Toivonen, H., "Adaptive On-Device Location Recognition," *LNCS*, Vol. 3001, 2004, pp. 287-304.
- [14] Lee, Y.P., "Deploying personalized mobile services in an agent-based environment," *Expert Systems with Applications*, Vol. 32, No. 4, 2007, pp. 1194-1207.
- [15] Loeffler, T., Sigg, S., Haseloff, S., and David, K., "The Quick Step to Foxtrot," *Proceedings of the Second Workshop on Context Awareness for Proactive Systems (CAPS 2006)*, K. David, O. Droegehorn, and S. Haseloff, Eds. Kassel University Press, 2006.
- [16] Mäntyjärvi, J., Himberg, J., and Huuskonen, P., "Collaborative Context Recognition for Handheld Devices," *Proceedings of the 1st IEEE International Conference on Pervasive Computing and Communications*, 2003, pp. 161-168.
- [17] Mayrhofer, R., "Context Prediction based on Context Histories: Expected Benefits, Issues and Current State-of-the-Art," *ECHISE*, 2005.
- [18] Nurmi, P., Martin, M., and Flanagan, J.A., "Enabling Proactiveness through Context Prediction," *CAPS*, 2005.
- [19] Petzold, J., F. Bagci, W. Trumler, and T. Ungerer, "Next location prediction within a smart office building," *1<sup>st</sup> Int. Workshop on Exploiting Context Histories in Smart Environments (ECHISE 2005) at the 3rd Int. Conference on Pervasive Computing*, 2005.
- [20] Projects of Industrial Ontologies Group, <http://www.cs.jyu.fi/ai/OntoGroup/projects.htm>.
- [21] Si, H., Kawahara, Y., Morikawa, H., and Aoyama, T., "A stochastic approach for creating context-aware services based on context histories in smart home," *1st International Workshop on Exploiting Context Histories in Smart Environments*, 2005, pp. 37-42.

- [22] Sigg, S., Haseloff, S., and David, K., "Minimising the Context Prediction Error," *IEEE 65th Vehicular Technology Conference*, 2007, pp. 272-276.
- [23] Sigg, S., Haseloff, S., and David, K., *Context Prediction by Alignment Methods*, 2006.
- [24] Son, B., Kim, Y., Nahm, E., and Kim, H., "Design of a User Location Prediction Algorithm Using the Flexible Window Scheme," *Korea Telecommunication Society Journal*, 2007, Vol. 32, No. 6, pp. 550-557.
- [25] Stephan, S., Sandra, H., and Klaus, D., "The Impact of the Context Interpretation Error on the Context Prediction Accuracy," *Third Annual International Conference on Mobile and Ubiquitous Systems: Networking and Services*, 2006, pp. 1-4.
- [26] Tennenhouse, D., "Proactive computing," *Communications of the ACM*, Vol. 43, 2000, pp. 43-50.
- [27] Terziyan, V., "Predictive and Contextual Feature Separation for Bayesian Metanetworks," *Lecture Notes in Computer Science*, Vol. 4694, 2008, pp. 634-644.
- [28] Van Setten, M., Pokraev, S., and Koolwaaij, J., "Context-aware recommendations in the mobile tourist application," *LNCS*, Vol. 3137, 2004, pp. 235-244.



◆ About the Authors ◆



**Ohbyung Kwon**

Ohbyung Kwon is presently a professor at Kyunghee University, South Korea, where he initially joined in 2004. In 2002, he worked Institute of Software Research International(ISRI) at Carnegie Mellon University to perform myCAMPUS project on context-aware computing, web service and semantic web. He received MS and PhD degree at KAIST in 1990 and 1995, respectively. He is now a adjunct professor at San Diego State University(SDSU). His current research interests include context-aware services, case-based reasoning and DSS. He has presented various papers in leading information system journals including Decision Support Systems, Simulation, International Journal of Computer Integrated Manufacturing, and Behavior and Information Technology.