

U-마켓에서의 사용자 정보보호를 위한 매장 추천방법*

김재경**, 채경희**, 구자철***

A Store Recommendation Procedure in Ubiquitous Market for User Privacy

Jae Kyeong Kim, Kyung Hee Chae, Ja Chul Gu

Recently, as the information communication technology develops, the discussion regarding the ubiquitous environment is occurring in diverse perspectives. Ubiquitous environment is an environment that could transfer data through networks regardless of the physical space, virtual space, time or location. In order to realize the ubiquitous environment, the Pervasive Sensing technology that enables the recognition of users' data without the border between physical and virtual space is required. In addition, the latest and diversified technologies such as Context-Awareness technology are necessary to construct the context around the user by sharing the data accessed through the Pervasive Sensing technology and linkage technology that is to prevent information loss through the wired, wireless networking and database. Especially, Pervasive Sensing technology is taken as an essential technology that enables user oriented services by recognizing the needs of the users even before the users inquire.

There are lots of characteristics of ubiquitous environment through the technologies mentioned above such as ubiquity, abundance of data, mutuality, high information density, individualization and customization. Among them, information density directs the accessible amount and quality of the information and it is stored in bulk with ensured quality through Pervasive Sensing technology. Using this, in the companies, the personalized contents(or information) providing became possible for a target customer. Most of all, there are an increasing number of researches with respect to recommender systems that provide what customers need even when the customers do not explicitly ask something for their needs.

* 이 연구는 서울시 산학연 협력사업(과제번호 : 10802)의 재래시장 활성화를 위한 u-Market 개발 과제로부터 지원을 받아 수행되었다.

** 경희대학교 경영대학 경영학과

*** 한국과학기술원 산업공학과

Recommender systems are well renowned for its affirmative effect that enlarges the selling opportunities and reduces the searching cost of customers since it finds and provides information according to the customers' traits and preference in advance, in a commerce environment. Recommender systems have proved its usability through several methodologies and experiments conducted upon many different fields from the mid-1990s. Most of the researches related with the recommender systems until now take the products or information of internet or mobile context as its object, but there is not enough research concerned with recommending adequate store to customers in a ubiquitous environment.

It is possible to track customers' behaviors in a ubiquitous environment, the same way it is implemented in an online market space even when customers are purchasing in an offline marketplace. Unlike existing internet space, in ubiquitous environment, the interest toward the stores is increasing that provides information according to the traffic line of the customers. In other words, the same product can be purchased in several different stores and the preferred store can be different from the customers by personal preference such as traffic line between stores, location, atmosphere, quality, and price.

Krulwich(1997) has developed Lifestyle Finder which recommends a product and a store by using the demographical information and purchasing information generated in the internet commerce. Also, Fano(1998) has created a Shopper's Eye which is an information proving system. The information regarding the closest store from the customers' present location is shown when the customer has sent a to-buy list. Sadeh(2003) developed MyCampus that recommends appropriate information and a store in accordance with the schedule saved in a customers' mobile. Moreover, Keegan and O'Hare(2004) came up with EasiShop that provides the suitable store information including price, after service, and accessibility after analyzing the to-buy list and the current location of customers.

However, Krulwich(1997) does not indicate the characteristics of physical space based on the online commerce context and Keegan and O'Hare(2004) only provides information about store related to a product, while Fano(1998) does not fully consider the relationship between the preference toward the stores and the store itself. The most recent research by Sedah(2003), experimented on campus by suggesting recommender systems that reflect situation and preference information besides the characteristics of the physical space. Yet, there is a potential problem since the researches are based on location and preference information of customers which is connected to the invasion of privacy.

The primary beginning point of controversy is an invasion of privacy and individual information in a ubiquitous environment according to researches conducted by Al-Muhtadi(2002), Beresford and Stajano(2003), and Ren(2006). Additionally, individuals want to be left anonymous to protect their own personal information, mentioned in Srivastava(2000).

Therefore, in this paper, we suggest a methodology to recommend stores in U-market on the basis of ubiquitous environment not using personal information in order to protect individual information and privacy. The main idea behind our suggested methodology is based on Feature Matrices model (FM model, Shahabi and Banaei-Kashani, 2003) that uses clusters of customers' similar transaction data, which is similar to the Collaborative Filtering. However unlike Collaborative Filtering, this methodology overcomes the problems of

personal information and privacy since it is not aware of the customer, exactly who they are. The methodology is compared with single trait model(vector model) such as visitor logs, while looking at the actual improvements of the recommendation when the context information is used. It is not easy to find real U-market data, so we experimented with factual data from a real department store with context information.

The recommendation procedure of U-market proposed in this paper is divided into four major phases. First phase is collecting and preprocessing data for analysis of shopping patterns of customers. The traits of shopping patterns are expressed as feature matrices of N dimension. On second phase, the similar shopping patterns are grouped into clusters and the representative pattern of each cluster is derived. The distance between shopping patterns is calculated by Projected Pure Euclidean Distance (Shahabi and Banaei-Kashani, 2003). Third phase finds a representative pattern that is similar to a target customer, and at the same time, the shopping information of the customer is traced and saved dynamically. Fourth, the next store is recommended based on the physical distance between stores of representative patterns and the present location of target customer.

In this research, we have evaluated the accuracy of recommendation method based on a factual data derived from a department store. There are technological difficulties of tracking on a real-time basis so we extracted purchasing related information and we added on context information on each transaction. As a result, recommendation based on FM model that applies purchasing and context information is more stable and accurate compared to that of vector model. Additionally, we could find more precise recommendation result as more shopping information is accumulated.

Realistically, because of the limitation of ubiquitous environment realization, we were not able to reflect on all different kinds of context but more explicit analysis is expected to be attainable in the future after practical system is embodied.

Keywords : Store Recommendation, Ubiquitous Market, Context-awareness, Feature Matrices Model

I. 서 론

최근 정보통신 기술의 발전에 따라 유비쿼터스 환경에 대한 논의가 다양한 관점에서 이루어지고 있다. 유비쿼터스 환경은 물리적 공간과 가상 공간의 구분이나 사용에 대한 시간 및 장소 제약 없이 네트워크에 접근하여 정보를 송수신할 수 있는 환경을 의미한다[Weiser, 1991]. 유비쿼터스 환경을 구현하기 위해서는 물리적 공간과 가상 공간의 경계 없이 사용자의 정보를 감지할 수 있는 센싱 기술 (Pervasive Sensing)이 필요하다. 그 외에도 센싱 기술을 통해 획득되는 각종 정보를

공유하여 사용자 주변 상황(Context)을 구성할 수 있도록 하는 상황인지 기술(Context-Awareness), 그리고 데이터베이스 및 효과적인 유무선 네트워킹을 통해 정보 공유의 단절이 발생하지 않도록 하는 연동 기술 등 다양한 최신 기술들이 필요하다. 특히 상황인지 기술은 사용자가 요구하기 전에 사용자의 요구사항을 파악할 수 있도록 함으로써, 사용자 중심의 서비스 제공이 가능하게 하는 핵심 기술로 인식되고 있다[Brown *et al.*, 1997].

이와 같은 기술들을 통해 유비쿼터스 환경은 편재성, 정보의 풍부성, 상호작용, 높은 정보밀도, 개인화 및 고객화 등으로 특징 되어진다. 그 중

정보밀도는 이용 가능한 정보의 양과 질을 의미하며, 상황인지 기술을 이용하여 양질의 정보가 대량으로 저장될 수 있다. 이를 활용하면 기업에서는 특정 고객에게 맞는 개인화된 정보 전달이 가능하므로, 현재에도 개인화를 위한 연구는 지속되고 있다.

추천 시스템은 고객의 성향이나 기호에 따라 관심을 가질 만한 상품 또는 정보를 미리 찾아내어 권함으로써 고객의 정보탐색 비용을 줄이고 기업의 판매 기회를 확대시킴으로써 상거래 환경에 긍정적인 영향을 주는 것으로 알려져 있다 [Schafer *et al.*, 1999]. 추천 시스템은 90년대 중반 이후부터 지금까지 여러 가지 방법론과 실험들을 통해 다양한 분야에 적용되어 유용성이 입증되어 왔다 [Rensnick *et al.*, 1994; Hill *et al.*, 1995; Schafer *et al.*, 1999, Jin *et al.*, 2005]. 지금까지 대부분의 추천 시스템 관련 연구는 인터넷 환경, 혹은 모바일 환경에서의 제품 또는 정보를 추천 대상으로 하고 있으며, 유비쿼터스 환경에서 고객에게 적합한 매장을 추천하는 연구는 아직 부족한 실정이다 [Montaner *et al.*, 2003].

유비쿼터스 환경에서는 고객이 오프라인 시장에서 소비활동을 하더라도 온라인 시장과 동일하게 고객의 행동 추적이 가능하다. 하지만 기존의 인터넷 공간과는 다르게 유비쿼터스 환경에서는 고객의 동선에 따라 매장 정보를 제공할 수 있으므로 매장 추천에 대한 필요성이 대두되고 있다 [Keegan and O'Hare, 2004]. 즉, 동일한 제품이라 하더라도 여러 매장에 동시에 존재할 수 있으며 매장 간의 동선, 매장 위치, 매장 분위기, 제품의 품질, 가격 등에 대한 개인의 취향에 따라 선호하는 매장은 다를 수 있기 때문이다.

Krulwich[1997]는 사용자의 인구통계학적인 정보와 전자상거래 상에서 발생하는 구매 정보를 이용하여 상품 및 매장을 추천하는 시스템인 Lifestyle Finder를 개발하였으며, Fano[1998]는 사용자가 자신의 구매 목록을 전송했을 경우, 위치를 추적하여 현재 위치에서 가장 가까운 매장 정보를 제

공해 주는 시스템, Shopper's Eye를 개발하였다. Sadeh 등[2003]은 모바일 인터페이스와 시멘틱 웹(semantic web) 환경을 기반으로 고객의 모바일에 저장된 일정을 파악하여 적절한 정보 및 매장을 추천해주는 MyCampus를 개발하였다. 또한 Keegan과 O'Hare[2004]는 고객이 전송한 구매 목록 데이터와 고객의 현재 위치를 분석하여 고객에게 가격, 판매 후 관리, 근접성 등의 조건이 좋은 매장의 정보를 제공해 주는 EasiShop을 개발하였다.

그러나 Krulwich[1997]의 연구는 전자상거래 환경을 기반으로 하여 물리적 공간의 특징을 반영하지 못하고 있으며, Fano[1998]의 연구는 물리적 공간의 특징을 반영하기는 하였으나, 매장의 위치 정보만을 사용했을 뿐, 상황정보나 고객의 선호를 반영하지 못한 한계가 있다. 그리고 Keegan과 O'Hare[2004]의 연구는 제품과 관련된 매장을 찾아내어 해당 매장에 대한 정보를 제공해 줄 뿐, Fano[1998]와 마찬가지로 매장에 대한 고객의 선호나 매장 간의 연관성에 대해서는 고려하지 못하고 있다. 가장 최근의 연구로써, Sadeh 등[2003]은 물리적인 공간의 특징 외에도 상황정보 및 고객의 선호도를 반영한 추천 시스템을 제안하여 캠퍼스 내에서 실험하기도 하였으나, 지금까지의 모든 매장 관련 연구처럼 과거 개인 정보를 바탕으로 한 선호 정보를 기반으로 하고 있어 개인 정보 유출과 개인 사생활 보호에 대한 문제는 해결하지 못한 상황이다.

최근에는 유비쿼터스 환경에 있어서 개인 정보보호 및 사생활 보호 문제가 중요한 논점으로 지적되고 있다 [Al-Muhtadi *et al.*, 2002; Beresford and Stajano, 2003; Ren *et al.*, 2006]. 또한 Srivastava 등[2000]의 연구에서는 개인은 스스로 자신의 정보 보호를 위해 익명성이 유지되기를 원하고 있음을 알 수 있다.

따라서 본 논문에서는 유비쿼터스 환경을 기반으로 하고 있는 시장, 즉 U-마켓에서 개인 정보 보호와 사생활 보호를 위해 개인 정보를 사용

하지 않고 매장을 추천하는 방법을 제시하고자 한다. 본 논문에서 제시하고자 하는 FM(*Feature Matrices*)모델 기반의 추천방법은 고객의 유사한 쇼핑패턴들을 군집화하여, 다음 방문 상점을 추천해 주는 방법으로 협업 필터링(*Collaborative Filtering: CF*) 추천방법과 유사하다. 그러나 고객이 누구인지를 인식하지 않고 추천함으로써 개인 정보 보호와 사생활 보호에 대한 문제를 극복할 수 있다. 본 논문에서 제시하고자 하는 방법론의 성능을 평가하기 위하여 상황정보를 이용하지 않고 방문기록과 같은 단일 속성의 방법론, 즉 벡터(*Vector*)모델과 비교 실험함으로써, 상황정보를 이용했을 때 추천의 성능이 얼마나 향상되었는지 살펴보았다. 현재 U-마켓 데이터를 획득하는데 어려움이 있으므로 실제 백화점 거래데이터에 상황정보를 추가하여 U-마켓 데이터를 구성하여 실험하였다.

본 논문의 구성은 다음과 같다. 제 II장 관련 연구에서는 유비쿼터스 환경에서의 추천 시스템 관련 연구들과 벡터모델, 상황에 대한 정의를 대해 살펴보았다. 제 III장에서는 FM모델 기반의 U-마켓 매장 추천 방법에 대해 설명하였으며, 제 IV장에서는 실제 데이터를 이용한 실험을 통하여 FM모델의 성능을 검증하였다. 그리고 마지막으로 제 V장에서는 본 논문의 결과 및 추후 연구방향을 제시하였다.

II. 관련 연구

2.1 유비쿼터스 환경에서의 추천시스템 관련 연구

추천에 대한 문제가 학술적으로 처음 발표된 것은 1990년대 중반이며, 다양한 분야에서 추천 시스템들이 사용되고 있다[Degemmis *et al.*, 2007; Hill *et al.*, 1995; Rensnick *et al.*, 1994].

일반적으로 알려진 추천 기법으로는 협업 필터링(*Collaborative Filtering, CF*) 기법과 내용기

반 필터링(*Content-Based Filtering, CB*) 기법이 있다. 내용기반 필터링 기법은 고객이 구매한 제품들의 속성을 비교하여 고객이 선호하는 제품 속성을 발견해 내고, 고객이 선호하는 속성과 유사한 속성의 제품을 추천하는 방법이다. 협업 필터링 기법은 각 고객들의 아이টে에 대한 평가를 기반으로 고객들 간의 유사도를 계산하여, 유사한 고객들을 이웃(*Neighbor*)이라고 정의한다. 그리고 이웃들이 선호하는 아이টে를 선별하여 추천하는 방법이다. 최근에는 추천 시스템의 성능을 높이기 위하여 두 가지 기법을 혼합한 하이브리드(*Hybrid*) 방법이 많이 사용되고 있다[Degemmis *et al.*, 2007; Pazzani, 1999].

협업 필터링 기법은 추천 성능이 비교적 뛰어난 것으로 알려져 있으나, 정확한 추천을 하기 위해서는 대량의 평가 정보가 누적되어 있어야 하고, 정보가 충분하지 않은 초기에는 추천 결과의 정확도가 떨어질 수 있으며, 개인 정보보호 문제가 발생할 수 있다는 것이 한계점으로 지적되고 있다[Sarwar *et al.*, 2000].

최근에는 추천 시스템이 점차 정교화되고 응용 방법 및 분야도 인터넷이나 모바일 환경에서 유비쿼터스 환경으로 확대되고 있다[Adomavicius and Tuzhilin, 2005]. Sadeh 등[2003]은 모바일 인터페이스와 시멘틱 웹(*Sementic Web*) 환경을 기반으로 한 추천 시스템, MyCampus를 제안하였다. 이 추천 시스템에 포함된 추천 에이전트는 고객이 입력한 PDA(*personal digital assistants*) 정보를 분석하고, CF 기법을 이용하여 고객의 상황에 맞는 정보나 캠퍼스 내에 있는 매장 등을 추천해 준다. Keegan과 O'Hare[2004]는 유비쿼터스 환경을 기반으로 고객이 전송한 구매 목록과 고객의 현재 위치를 분석하여 가장 가까운 매장들의 가격정보, 판매 후 관리 정보 등을 제공해주는 시스템, EasiShop을 개발하였다. Lemire 등[2005]은 시멘틱 웹 기반의 e-Learning 환경에서 CF 기법으로 고객의 상황에 맞는 학습 객체를 추천해 주는 시스템을 개발하였다. 그리고 Kim

등[2006]은 유비쿼터스 환경에 P2P(peer to peer) 방식을 적용한 추천 시스템으로써 UREC_P2P를 제안하였다. UREC_P2P는 CF 방식으로 사전에 정의된 고객의 이웃 정보와 현재의 위치 정보를 이용하여 제품을 추천해 주는 시스템이다.

앞서 설명한 기존의 연구들은 모바일 환경이나 유비쿼터스 환경에서 새로운 추천 시스템을 제안하고 있으나, 고객의 위치 정보나 과거 구매 정보와 같은 개인 정보를 활용함으로써, 고객의 정보보호 및 사생활 보호에 대한 문제는 여전히 해결하지 못한 상황이다. 따라서 본 논문에서는 고객의 과거 구매기록을 이용하지 않고 익명의 정보를 활용하여 추천하는 FM모델을 사용함으로써 고객의 정보를 보호하고자 하였다. 또한 군집분석을 통해 유사 패턴들을 사전에 정의해 놓음으로써, CF 기법이 가진 초기 추천 문제를 해결하고 실시간 추천이 가능하도록 하였다.

2.2 벡터모델

벡터모델은 온라인 환경을 기반으로 개발된 웹 사용 마이닝(web-usage mining) 방법 중 하나로써, 익명의 사용자 세션(user session) 패턴을 벡터로 표현하여 분석하는 방법이다[Yan, et al., 1996]. 웹사용 마이닝에서는 웹에 방문한 고객들을 사용자라 하며, 세션은 사용자가 특정 사이트에 접속하여 종료하기까지 탐색한 일련의 웹 페이지들으로써, 각 페이지들은 서로 링크(link)되어 있다.

벡터모델은 사용자의 ID와 상관없이 사용자 세션 패턴만을 이용하여 분석하는데, 접속 중인 사용자의 세션 패턴을 통해 방문 가능성이 높은 웹 페이지들을 정의하고, 페이지들 간의 링크를 실시간으로 재구성하여 사용자에게 보여준다. 벡터모델은 사용자가 방문했던 페이지들은 서로 독립적이라는 것을 전제로, 방문한 순서에 대해서도 고려하지 않는다. 따라서 일시적으로 ID가 부여된 익명의 사용자 패턴은 사용자가 선택한 웹

문서와 해당 문서의 방문 빈도에 의해 식 (1)과 같은 벡터로 표현된다. 즉, 사용자 i 의 세션 패턴 V_i 는 순서에 상관 없이 사용자가 방문한 m 페이지, 즉 PID_m 와 해당 페이지에 대한 방문횟수인 n_m 으로 표현되며, 유클리디안 거리 공식을 이용하여 세션 패턴간의 유사성을 분석한다.

$$V_i = \{(PID_1, n_1), (PID_2, n_2), \dots, (PID_m, n_m)\} \quad (1)$$

벡터모델을 확장한 방법으로 FM모델이 있다 [Shahabi and Banaei-Kashani, 2003]. 벡터모델에서는 사용자의 방문빈도, 즉 하나의 속성만을 이용하여 웹 사용 패턴을 분석하는 반면, FM모델은 웹 페이지 방문횟수(hit), 방문순서(sequence), 열람시간(view time) 등, 다차원의 속성을 이용하여 사용자의 웹 사용 패턴을 표현할 수 있다. 또한 FM모델에서는 웹 페이지 간의 상관관계를 고려하여 웹 페이지 방문횟수, 방문순서 등의 속성을 표현할 때, 구간(segment)을 정의하여 매트릭스(matrix)로 표현한다. 즉, 2차원 구간으로 속성을 표현한다고 가정한다면, 사용자가 방문한 페이지 중 시간적으로 인접한 2개의 페이지를 동시에 고려한 것이며, 이는 두 페이지 간의 암묵적인 연관성까지 고려한 것이다. 따라서 본 연구에서는 웹에서의 사용자 패턴을 분석하는 FM모델을 U-마켓에서 상점추천에 활용한다. 즉, 고객이 방문한 매장들 간의 연관성을 고려하고, 유비쿼터스 환경에서 수집 가능한 고객의 위치, 환경 및 시간 정보와 같은 상황정보를 속성에 추가함으로써 U-마켓에서의 상점 추천에 사용한다.

2.3 U-마켓을 위한 상황정보

초기 형태의 상황정보(context)에 대한 정의는 Brown[1997 등]에 의해 이루어졌다. Brown[1997] 등은 상황정보를 위치, 사용자 주변 인물에 대한 신원 정보, 시간, 계절, 온도정보 등 다섯 가지로 정의하였다. 다음으로 Ryan[1997] 등은 상황정보

를 사용자의 위치, 환경, 신원 및 시간정보라 정의하였으며, Dey[1998]는 사용자의 감성 상태, 주목하고 있는 대상, 위치, 시간, 주변 인물 및 대상 등의 정보라고 정의하였다. 그 후, Dey[1999] 등은 기존 연구들을 종합하여 상황정보를 사용자와 응용서비스 사이의 상호작용을 위해 필요한 사용자, 장소, 대상물 등의 개체 상태를 나타내는 정보라고 정의하였으며, 이 개념이 최근 여러 사람들에게 의해 많이 참조가 되고 있다.

그러나 기존의 상황정보에 대한 정의는 응용 측면에 있어서는 몇 가지 문제점이 지적되고 있다. 예를 들어, 각각의 응용서비스에서 사용되는 상황정보는 특정 응용서비스를 위해 정의됨으로써, 다른 응용서비스에서는 사용이 불가능하거나 수정해야 한다는 것이다.

<표 1> 상황정보 관련 연구

관련연구	상황에 대한 정의
Brown <i>et al.</i> [1997]	위치, 사용자 주변 인물에 대한 정보, 시간, 계절, 온도 정보 등
Ryan <i>et al.</i> [1997]	사용자 위치, 환경, 신원 및 시간 정보 등
Dey[1998]	사용의 감정, 관심 대상, 위치, 시간, 주변 인물에 대한 정보 등
Dey <i>et al.</i> [1999]	사용자 신원, 장소, 대상물 등의 개체에 대한 정보
Jang and Woo[2003]	사용자 신원, 대상, 장소, 시간, 감정, 행동 정보 등

이와 같은 문제를 해결하기 위하여 Jang과 Woo[2003]는 상황을 5W1H, 즉 사용자 신원정보(Who), 주목하고 있는 사람이나 물건과 같은 대상(What), 장소(Where), 시간(When), 기분상태(Why), 차를 타거나 혹은 걷거나 앉기, 서기 등과 같은 사용자의 동작(How) 등으로 정의하였다. Jang과 Woo[2003]의 연구는 다양한 응용분야에 활용될 수 있는 보편적인 정의의 기준을 제시하였으나, 실제 구현하기에는 다양한 분야에서의 검증이 필요하다. 또한 본 논문의 실험에 사용되

는 데이터를 확보하기 어려우므로, 초기에 연구된 Ryan[1997] 등의 정의를 활용하여 매장 추천에 필요한 상황정보를 사용자의 위치, 환경, 시간 정보로 정의하였다. 하지만 상황정보를 다르게 정의하더라도 제시한 방법론을 적용하는 것에는 전혀 문제가 없는 상황이다.

Ⅲ. FM모델 기반의 U-마켓 매장 추천 방법

U-마켓은 유비쿼터스 기술이 도입된 시장으로써, 물리적 공간에 존재하는 다양한 매장들, 제품이나 기기 및 건물 등과 같은 매장 구성 요소들, 그리고 종업원 및 고객들과 같이 매장을 이용하는 구성원들이 가상으로 연결되어 실시간으로 커뮤니케이션이 가능한 공간을 의미한다.

U-마켓에서는 고객이 언제, 어느 매장을 방문하여, 누구와 함께, 어떤 제품을, 얼마나 구매했는지 등의 상황정보를 추적할 수 있다. Sadeh 등[2003], Keegan과 O'Hare[2004], Lemire 등[2005], 그리고 Kim 등[2006]과 같은 최근 논문들에서 이와 같은 고객의 다양한 상황정보들을 활용함으로써 추천의 정확성 및 유용성을 향상시키는 연구가 진행되고 있다. 한편에서는 U-마켓에서 고객의 사생활 및 정보보호 문제가 중요한 이슈로 부각되어 이를 해결하기 위한 연구가 진행되고 있는 상황이다[Al-Muhtadi *et al.*, 2002; Beresford and Stajano, 2003; Ren *et al.*, 2006]. 이 연구에서 제시하고 있는 U-마켓에서 매장 추천을 위한 FM 모델은 고객 정보를 수집함에 있어 익명성을 보장하기 때문에 고객의 사생활 정보를 보호할 수 있는 방법이다.

FM모델 기반의 U-마켓 매장 추천방법에서는 고객이 U-마켓을 방문한 순간 고객에게 일시적인 ID를 부여한다. 그리고 고객이 방문한 매장들, 구매한 제품들, 관련 상황정보 등을 수집하여 U-마켓 서버에 저장한다. 고객들의 매장 방문경로, 제품 구매경로, 그리고 해당 시점에서의 상황정

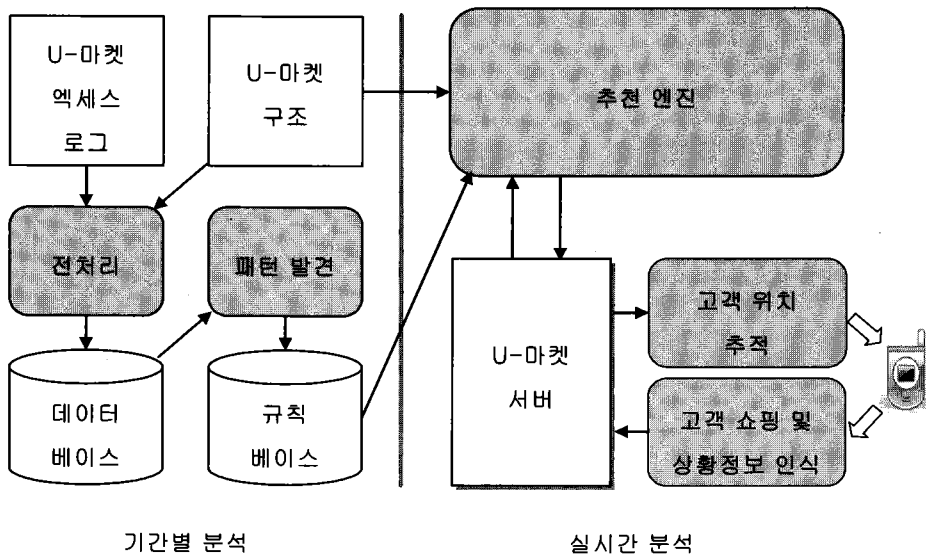
보 등의 경로 구성요소들을 통해 고객들의 쇼핑 패턴을 정의한다. 고객들의 쇼핑패턴은 일시적인 ID로 구분되므로 동일한 고객이 여러 개의 ID를 가질 수 있다. 유사한 쇼핑패턴 및 상황정보를 이용하여 유사한 쇼핑패턴들로 구성된 군집을 형성하고 군집의 대표 패턴을 도출한다. 그리고 고객이 U-마켓에서 쇼핑하기 위하여 매장을 방문하면, 매장 방문 기록과 유사한 군집의 대표 쇼핑 패턴을 찾아서 다음 매장을 추천함으로써 추천의 효율성과 적시성을 높이도록 하였다. 본 논문에서 제시하는 추천 방법에 필요한 기본적인 개념들을 정리하면 다음과 같다.

- U-마켓: 물리적 매장 및 매장 구성요소, 구성원들이 가상으로 연결되어 있는 공간
- 경로: 고객이 U-Market에 들어와서 나가기 까지 발생하는 유한의 고객 활동 흐름
- 요소: 경로를 구성하는 요소(예: 방문 횟수, 방문순서, 구매횟수, 구매순서, 머문 시간 등등)
- 매장: 경로를 구성하고 있는 매장들

- 구역: 매장의 부분집합(서로 연관성이 있다고 판단되는 연속적 매장 집합)
- 쇼핑패턴: 고객의 방문 경로 및 구매 경로, 그리고 해당 시점의 경로 구성요소에 의해 정의된 고객들의 쇼핑 특징
- 군집: 유사한 쇼핑패턴들의 집합

3.1 U-마켓 매장 추천 시스템 구조

본 논문에서 제시하고자 하는 매장 추천 시스템 구조는 <그림 1>과 같다. 매장 추천 방법의 구조는 크게 기간별 분석과 실시간 분석으로 구분된다. 기간별 분석은 추천의 적시성을 높이기 위해 사전에 고객 쇼핑패턴들에 대한 유사성을 분석하여 저장하는 역할을 한다. 기간별 분석에서는 먼저, 고객들이 U-마켓 내에서 발생시킨 쇼핑관련 정보, 구매관련 정보, 상황정보와 같은 액세스 로그와 함께 고객이 들어온 입구, 고객이 방문한 매장명 및 매장의 위치와 같은 U-마켓 구조 등을 전처리하여 데이터베이스에 저장한다. 이때, 고객의 쇼핑관련 정보는 매장의 방문횟수, 방



<그림 1> U-마켓 매장추천 시스템 구조

문순서 등과 같은 정보를 의미한다. 구매관련 정보는 제품을 구매한 매장, 구매가 발생한 매장에 대한 구매횟수, 구매가 발생한 매장에 대한 구매순서, 매장별 구매 금액, 매장별 구매한 제품의 개수 등과 같은 정보를 의미한다. 상황정보는 고객이 각 매장에 머문 시간, 구매 시간, 구매 시점의 날씨 등과 같은 정보를 의미한다. 다음으로 이와 같은 정보를 기반으로 쇼핑패턴들의 유사성을 분석한다. 유사하다고 판단되는 쇼핑패턴들은 하나의 군집으로 형성되고 대표 쇼핑패턴을 갖는다. 대표 쇼핑패턴은 규칙베이스에 저장되고 추천 엔진에서 추적 중인 고객의 패턴과 유사한 대표 패턴을 검색할 때, 활용된다.

실시간 분석은 고객이 U-마켓의 입구에 들어오는 순간, 고객에게 일시적인 아이디(ID)를 부여한 후에 고객이 U-마켓을 떠날 때까지 모든 쇼핑관련 활동들을 추적하면서 고객에게 적절한 매장을 지속적으로 추천해 주는 역할을 한다. U-마켓 서버에서는 고객이 쇼핑 및 상황정보를 실시간으로 추적하여 추천 엔진에 전송한다. 추천 엔진에서는 규칙베이스로부터 전송된 정보와 가장 유사한 대표 쇼핑패턴을 검색하여 추천할 매장들의 목록을 구성한 후에 다시 U-마켓 서버로 전송한다. 그리고 서버에 전송된 목록 중에서 고객의 현 위치와 가장 가까운 매장 및 매장 관련 정보가 고객의 단말기로 전송된다. 이 때, 추천할 매장들의 목록은 추적 중인 고객의 정보가 갱신될 때마다 새롭게 구성된다.

3.2 U-마켓 매장 추천 절차

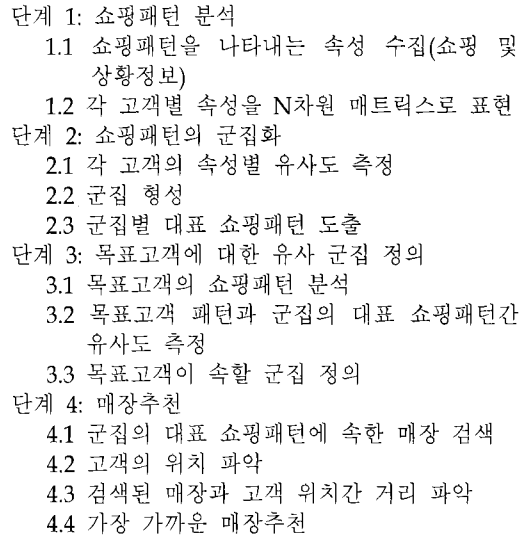
U-마켓 매장 추천 절차는 <그림 2>와 같이 크게 네 단계로 구성된다. 첫 번째 단계는 고객들의 쇼핑 패턴 분석에 필요한 정보들을 수집하고 전처리하는 단계로써, 첫 번째 단계에서 쇼핑패턴을 나타내는 각 속성들은 N 차원의 매트릭스(Feature Matrices)로 표현된다.

두 번째 단계에서는 매트릭스로 표현된 고객들

의 쇼핑패턴 간의 거리를 PPED(Projected Pure Euclidean Distance)방법으로 계산하여, 유사한 고객들의 쇼핑패턴들을 군집화 한 후, 군집 내 속성 값들의 산술 평균을 통해 군집을 대표할 수 있는 패턴을 추출한다.

세 번째 단계에서는 고객이 U-마켓에서 쇼핑을 위하여 매장을 방문하면, 매장 방문기록과 구매기록, 그리고 상황정보를 데이터베이스에 저장함과 동시에 해당 고객(목표고객)의 쇼핑 패턴과 유사한 군집의 대표 쇼핑패턴을 찾는다.

네 번째 단계에서는 군집의 대표 패턴에 포함된 매장들과 현재 고객 위치와의 물리적 거리를 비교하여, 가장 가까운 다음 매장을 고객에게 추천하고 매장에서 제공하고자 하는 정보를 제시한다. 다음 매장을 추천할 때, 기존에 고객이 방문했던 매장들은 제외된다.



<그림 2> U-마켓 매장추천 절차

3.2.1 쇼핑패턴 분석

U-마켓 고객의 쇼핑패턴을 분석하기 위해 본문에서는 FM모델을 응용하여 사용한다. 매장 추천 방법에 있어서 U-마켓에 포함된 매장의 수

는 r 로 표현되며, 고객 쇼핑패턴 U^m 은 식 (2)와 같다. m 번째 속성, 즉 F_m 은 각각 n 개 차원으로 표현된 매트릭스($M_{r,n}^{F_m}$)로 나타난다.

$$U^m = \{M_{r,n_1}^{F_1}, M_{r,n_2}^{F_2}, \dots, M_{r,n_m}^{F_m}\} \quad (2)$$

FM모델에서는 방문횟수, 방문순서, 열람시간과 같은 속성을 이용하여 웹 사용자들의 패턴을 분석하였다. 본 논문에서는 U-마켓 환경을 고려하여 기존 연구에서 사용되었던 방문 횟수(Hit: H), 방문순서(Sequence: S) 등의 속성들은 예와 같이 재정의하였으며, 열람시간은 매장에 머문시간(Duration time: Dt)으로 재정의하였다. 또한 FM모델 분석에 포함되는 속성으로 구매정보 파악을 위한 구매횟수(Purchase: P), 구매순서(Order: O), 구매금액(Monetary: M), 및 구매한 제품 개수(Count: C) 등을 추가하였으며, 유비쿼터스 환경에서 고객을 이해하는데 매우 중요한 상황정보인 방문시간(Visiting time: Vt)과 날씨(Weather: Wt) 등을 추가하였다. 그리고 <그림 1>에서 나타난 바와 같이 고객에게 매장을 추천할 때 고객의 현재 위치를 기반으로 가까운 매장을 추천함으로써, 기본적인 상황정보인 시간, 날씨, 위치 정보를 고려하여 분석하였다.

이와 같은 속성들은 연관 속성들과 독립 속성들로 구분될 수 있다. 연관 속성은 앞서 발생한 이벤트와 그 다음으로 발생한 이벤트가 연속선상에 있는 속성을 의미하며, 독립 속성은 앞서 발생한 이벤트와 다음 이벤트가 서로 독립적으로 발생하는 속성을 의미한다. Shahabi와 Banaei-Kashani[2003]의 연구에서는 방문횟수와 방문순서를 연관 속성으로, 방문시간은 독립 속성으로 판단하여 연관 속성은 N차원의 매트릭스로, 독립 속성은 1차원의 매트릭스로 표현하였다. 이와 같은 내용을 참조하여 본 논문에서는 방문횟수, 방문순서, 구매횟수, 구매순서 등을 N차원의 매트릭스로 표현하고, 그 외의 속성들은 1차원의

속성으로 표현하고자 한다.

예를 들어, 시장 내의 매장이 x_1 부터 x_3 까지 3개가 있고, 연속선 상에서 발생한 2개의 매장에 대하여 살펴본다고 가정할 때, 고객의 쇼핑패턴은 식 (3)과 같다. 연속선 상의 2개 매장에 대해 살펴보기 때문에, 식 (3)의 H, S, P, O 등의 연관 속성은 식 (5)와 같은 2차원의 매트릭스로, 또한 Dt, M, C, Vt, Wt 등의 독립 속성은 식 (4)와 같은 1차원의 매트릭스로 표현된다.

$$U^m = \{M_{3,2}^H, M_{3,2}^S, M_{3,2}^P, M_{3,2}^O, M_3^T, M_3^M, M_3^F, M_3^V, M_3^W\} \quad (3)$$

$$\epsilon^{(1)} = \{(x_1, x_2, x_3)\} \quad (4)$$

$$\epsilon^{(2)} = \begin{Bmatrix} (x_1, x_1) & (x_1, x_2) & (x_1, x_3) \\ (x_2, x_1) & (x_2, x_2) & (x_2, x_3) \\ (x_3, x_1) & (x_3, x_2) & (x_3, x_3) \end{Bmatrix} \quad (5)$$

식 (3)에 포함된 각 속성에 대해 예를 들어 설명하면 다음과 같다.

- 방문횟수: 각 구역, 즉 매장 집합에 대한 방문횟수를 의미한다. 예를 들어, 고객의 쇼핑패턴이 ' $x_1 \rightarrow x_2 \rightarrow x_3 \rightarrow x_2 \rightarrow x_3 \rightarrow x_1$ '의 경로를 나타내며, 직전에 방문했던 매장과와의 연관성을 고려하여 2개의 구역으로 나누어 방문횟수를 살펴본다고 가정한다면, 방문횟수는 식 (5)와 같은 2차원 매트릭스에 (x_1, x_2) 는 '1', (x_2, x_3) 은 '2', (x_3, x_2) 는 '1', (x_3, x_1) 은 '1'로 표현되고 나머지는 모두 '0'으로 표현된다.
- 방문순서: 각 구역의 순서, 즉 경로 상에서 매장집합이 위치하는 순서를 의미한다. ' $x_1 \rightarrow^1 x_2 \rightarrow^2 x_3 \rightarrow^3 x_2 \rightarrow^4 x_3 \rightarrow^5 x_1$ '경로의 예를 살펴보면, 방문순서는 식 (5)와 같은 2차

원 매트릭스에 (x_1, x_2) 는 '1'로 표현되며, (x_2, x_3) 은 '2'와 '4'에 걸쳐 두 번 나타났으므로 $(2+4)/2$, 즉 '3'으로 표현된다. 그리고 (x_3, x_2) 는 '3', (x_3, x_1) 은 '5'로 표현되고 나머지는 모두 '0'으로 표현된다.

- 구매횟수: 제품을 구매한 구역의 횟수를 의미한다. 이 때, 구매한 매장들의 순서만을 살펴보면, 구매가 발생한 매장들 사이에 존재하는 방문 매장은 전혀 고려하지 않는다. 예를 들어, 위와 같은 경로의 쇼핑 패턴을 보인 고객이 첫 번째 방문한 매장과 네 번째, 다섯 번째 방문한 매장, 즉 $'x_1'$ 과 $'x_2'$, x_3' 에서 제품을 구매했다면, 구매횟수는 식 (5)와 같은 2차원 매트릭스에 (x_1, x_2) 는 '1', (x_2, x_3) 는 '1'로 표현되고 나머지는 모두 '0'으로 표현된다.
- 구매순서: 제품을 구매한 구역의 순서를 의미한다. 구매순서 또한 구매횟수와 마찬가지로 구매가 발생한 매장들의 순서만을 고려할 뿐, 그 사이에 존재하는 방문 매장은 전혀 고려하지 않는다. 위와 같은 방문순서에서 구매횟수의 예와 동일하게 구매가 발생했다면, 구매순서는 식 (5)와 같은 2차원 매트릭스에 (x_1, x_2) 는 '1', (x_2, x_3) 는 '2'로 표현되고 나머지는 모두 '0'으로 표현된다.
- 머문시간: 각 매장 안에서 머문 시간으로, 독립 속성이다. 예를 들어, 방문순서와 같은 경로에서 고객이 첫 번째 매장 x_1 에서 10분, 두 번째 매장 x_2 에서 15분, 세 번째 매장 x_3 에서 10분, 네 번째 매장 x_2 에서 5분, 다섯 번째 매장 x_3 에서 3분, 여섯 번째 매장 x_1 에서 5분을 머물렀다면, 머문시간은 식 (4)와 같은 1차원의 매트릭스에 (x_1) 은 '10+ 5', 즉 '15', (x_2) 는 '15+5', 즉 '20', (x_3) 은 '10 +3', 즉 '13'으로 표현된다.
- 구매금액: 각 매장에서의 구매한 금액을 의미하며, 비율로 표현한다. 예를 들어, 고객이 x_1 에서 천원, x_2 에서 삼천원, x_3 에서 천원

을 소비했다면, 고객은 해당 시점에서 총 오천원을 소비한 것이다. 따라서 구매금액은 식 (4)과 같은 1차원 매트릭스에 (x_1) 은 '1/5', 즉 '0.2', (x_2) 는 '3/5', 즉 '0.6', (x_3) 은 '1/5', 즉 '0.2'로 표현된다.

- 구매개수: 각 매장에서의 제품 구매개수를 의미하며, 구매금액과 마찬가지로 비율로 표현한다. 예를 들어, 고객이 x_1 에서 세 개의 제품을, x_2 에서 두 개의 제품을, x_3 에서 한 개의 제품을 구매했다면, 고객은 해당 시점에서 여섯 개의 제품을 구매한 것이다. 따라서 구매개수는 식 (4)과 같은 1차원 매트릭스에 (x_1) 은 '3/6', 즉 '0.5', (x_2) 는 '2/6', 즉 '0.3', (x_3) 은 '1/6', 즉 '0.2'로 표현된다.
- 방문시간: 각 매장에 고객이 방문할 때의 시간을 의미하며, 명목 값으로 표현한다. 예를 들어, 고객이 첫 번째 매장 x_1 에 방문한 시간이 10시 30분이고, 두 번째 매장 x_2 은 11시 정각에, 세 번째 매장 x_3 은 11시 30분에, 네 번째 매장 x_2 은 11시 50분에, 다섯 번째 매장 x_3 은 12시 15분에, 여섯 번째 매장 x_1 은 12시 30분에 방문했다고 가정한다. 그리고 개점시간부터 12시 미만까지를 '1', 12시부터 3시 미만까지를 '2', 3시부터 6시 미만까지를 '3', 6시부터 폐점 시간까지를 '4'라고 입력 할 때, 방문시간은 식 (4)와 같은 1차원의 매트릭스에 (x_1) 은 두 번의 방문 중에 한번은 '1', 다른 한번은 '2'의 시간대에 방문했으므로 '1, 2', (x_2) 는 두 번 모두 '1'의 시간대에 방문했으므로 '1', (x_3) 은 '1, 2'로 표현된다.
- 날씨: 각 매장을 방문했을 때의 날씨를 의미하며, 방문시간과 같이 명목 값으로 표현한다. 예를 들어 위와 같은 경로에서 고객이 네 번째 매장을 방문할 때까지는 '구름'이었으나, 오후로 접어들면서 다섯 번째 매장을 방문할 때에는 소나기가 내렸다고 가정한다. 그리고 날씨가 맑음은 '1', 구름은

'2', 비는 '3'으로 입력할 때, 날씨는 식 (4)와 같은 1차원 매트릭스에 (x_1) 은 두 번의 방문 중에 한번은 구름, 한번은 비였으므로 '2, 3', (x_2) 는 두 번 모두 구름이었으므로 '2', (x_3) 은 '2, 3'으로 표현된다.

3.2.2 쇼핑패턴의 군집화

고객 행동에 따라 즉각적으로 분석하여 추천하기 위해서 개별 쇼핑패턴을 몇 개의 유사한 패턴으로 미리 정의하였다. 유사한 쇼핑패턴들은 하나의 군집으로 군집화 함으로써 시스템의 속도를 향상시키고 추천의 적시성을 높일 수 있게 된다.

군집을 위해 본 논문에서는 Kaufman과 Rousseuw의 연구[1990]에서 소개된 계층적 군집분석(hierarchical clustering)의 합산(agglomerative) 방법을 이용하였으며, 거리계산은 PPED(Projected Pure Euclidean Distance)방법을 사용한다[Shahabi and Banaei-Kashani, 2003]. 식 (6)과 같이 PPED 방법은 개체 A를 구성하고 있는 값 a_i 가 '0'이 아닌 경우에 한하여 개체 B를 구성하고 있는 값 b_i 와 비교하여 거리를 계산한다. 만일 a_i 와 b_i 가 문자라면 같거나 다른 경우만 존재하므로 a_i 와 b_i 가 같으면 '0', 다르면 '1'로 표현한다.

$$PPED(\vec{A}, \vec{B}) = \left(\sum_{i=1, a_i \neq 0}^N (a_i - b_i)^2 \right)^{\frac{1}{2}} \quad (6)$$

군집에 포함된 각 쇼핑패턴들은 식 (7)과 같이 군집의 대표 쇼핑패턴인 C^m 으로 통합되고, C^m 은 각 군집에 포함된 n 번째 속성들에 대한 대표 속성 M^F 에 의해 표현된다. 이때, M^F 가 숫자라면 식 (8)과 같이 군집에 포함된 N 개의 쇼핑패턴들에 대한 산술평균(arithmetic averaging)에 의해 대표 값을 산출한다. 그리고, 대표 속성이 문자라면 군집에 포함된 모든 값들 중 빈도가 가장 높

은 것을 대표 값으로 선택한다.

$$C^m = \{M^{F_1}, M^{F_2}, \dots, M^{F_n}\} \quad (7)$$

$$M^F = \frac{1}{N} \sum_{i=1}^N M_i^F \quad (8)$$

예를 들어, 쇼핑패턴 '1'과 쇼핑패턴 '2'가 하나의 군집에 속해 있고, 쇼핑패턴 '1'과 '2'의 속성 'H'가 다음의 식 (9)와 같다면, 군집을 대표하는 'H'의 매트릭스는 식 (10)과 같이 나타난다.

$$M_1^F = \left\{ \begin{array}{ccc} 0 & 1 & 0 \\ 0 & 0 & 2 \\ 1 & 1 & 0 \end{array} \right\} \quad M_2^F = \left\{ \begin{array}{ccc} 0 & 0 & 2 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{array} \right\} \quad (9)$$

$$M^F = \frac{1}{2}(M_1^F + M_2^F) = \left\{ \begin{array}{ccc} 0 & 0.5 & 1 \\ 0 & 0 & 1.5 \\ 0.5 & 1 & 0 \end{array} \right\} \quad (10)$$

이와 같이 대표속성을 지닌 군집을 형성하기 위해서는 PPED 방법을 이용하여 쇼핑패턴 간에, 또는 이미 형성된 군집과 쇼핑패턴 간에 거리를 계산해야 한다. 패턴들은 각각 m 개의 속성으로 구성되어 있으므로 최종적인 거리 D^F 를 계산하기 위해서는 먼저, 각 속성별로 거리를 계산한 다음, 식 (11)과 같이 속성 i 의 중요도(w_i)에 따라 가중평균(weighted average)한다.

$$D^F = \sum_{i=1}^m w_i \times D^{F_i} \quad \left(\sum_{i=1}^m w_i = 1 \right) \quad (11)$$

3.2.3 목표고객에 대한 유사군집 정의

목표고객에 대한 유사군집 정의 단계는 앞서 설명한 쇼핑패턴의 군집화 단계와 동일한 방법으로 실행된다. 그러나 쇼핑패턴의 군집단계까지는 기간별 분석 영역으로써, 익명의 고객들이 남긴 기존의 쇼핑패턴을 기반으로 고객들의 일반

적인 쇼핑패턴들을 파악한 반면, 목표고객에 대한 유사군집 정의 단계는 실시간 분석되는 영역으로써, 실시간 추천을 위해 운영된다는 점에서 차이가 있다.

U-마켓 영역으로 들어오면, 시스템에서는 일시적으로 고객ID를 생성하여 목표고객에게 부여한 후, 식 (3)에 나타난 9개 속성과 관련된 정보를 지속적으로 추적하여 갱신한다. 목표고객의 쇼핑패턴에 대한 정보가 생성 또는 갱신될 때마다 <그림 1>의 추천도틀에서는 PPD 방법을 이용한 가중평균 D^F 를 통해 목표고객의 쇼핑패턴과 유사한 대표패턴을 갖는 군집을 검색한다. 이와 같이 목표고객 정보 갱신에 따른 유사군집의 정의는 고객이 U-마켓 영역을 벗어나 추적이 불가능할 때까지 반복된다.

3.2.4 매장추천

목표고객의 쇼핑패턴과 유사한 군집이 정의될 때마다, 군집에 포함된 매장들을 목표고객에게 추천하며, 추천되는 매장들은 고객의 쇼핑 및 상황정보가 갱신됨에 따라 달라질 수 있다. 본 논문에서 제시하는 시스템 구조에서는 추천 엔진에서 검색된 추천 매장 목록들과 현재 목표고객의 위치에 대한 물리적 거리를 계산하여, 가장 가까운 매장 및 매장 정보를 고객에게 추천한다. 그러나 고객의 위치추적이 불가능한 상황에서는 군집 내에서 가장 빈번한 Top N개의 매장을 추천한다. 단, 추천 매장 목록에서 기존에 고객이 방문했던 매장들은 제외된다.

IV. 성능평가

본 논문에서 제시하는 방법에 대한 유용성 검증 위해 실제 백화점 데이터를 수집하여 추천의 정확도를 평가해 보았다. 현재 기술적인 상황에서 실시간 정보 추적은 어렵기 때문에, 실험에서는 백화점의 거래 정보와 관련된 상황 정보만


을 추출하여 실험하였다.

백화점의 구매 데이터는 계절적 요인 및 기타 행사 등의 영향을 최소화할 수 있는 2007년 6월~8월까지의 구매 데이터를 활용하였으며, 총 1842개의 거래 데이터에는 409개의 매장, 378명의 고객, 그리고 442개의 경로가 포함되어 있다. 실험의 성능평가를 위하여 경로는 최소 5개 이상의 매장을 방문한 거래들로 구성된 442개의 경로를 선별하였다. 442개의 경로는 6~7월에 포함된 302개 경로와 8월에 포함된 140개 경로로 구성되어 있다.

모델의 정확성을 평가하기 위하여 한번에 1개의 매장을 추천하는 Top 1 방법에서 6개의 매장을 추천하는 Top 6 방법까지, 추천하는 매장 개수를 달리하면서 매장추천의 정확도(precision)와 재현율(recall), 그리고 F1 값을 비교하였다. 군집형성을 위해 6월과 7월의 데이터를 활용하였으며, 정확도 검증을 위해 8월에 발생한 647개의 거래 데이터를 활용하였다. 또한 제안한 방법의 성능을 검증하기 위하여 상황정보를 고려하지 않은 벡터모델과 비교 실험하였다.

4.1 쇼핑패턴 분석

FM모델의 장점은 여러 속성들을 추가하여 분석하는 것이 가능하다는 것이다. 실험을 위해 백화점의 고객 구매 정보 중에서 구매횟수, 구매순서, 그리고 구매개수 속성, 상황 정보 중에서는 구매 당시의 날씨와 시간 속성에 대한 정보를 수집하여, 총 5가지 속성 정보를 이용하여 고객의 쇼핑패턴을 분석하였다. 이때, 구매횟수와 구매순서는 2차원의 데이터로 표현하였으며, 그 외의 속성들은 1차원 데이터로 표현하였다. 또한 상황 정보는 문자로 나타냈으며, 날씨를 맑음을 '1', 구름을 '2', 흐림을 '3', 비나 눈을 '4'로 나타냈다. 그리고 백화점 개점이 10시 전 후로 이루어지고, 폐점이 8시 전후로 이루어지므로, 개점 후 12시 미만까지는 '1', 12시부터 3시 미만까지



<그림 3> 거리 임계치에 따른 군집의 수

는 '2', 3시부터 6시 미만까지는 '3', 6시부터 폐점시간까지는 '4'로 나타났다. 또한 같은 날 동일한 고객에 의해 발생된 거래데이터들은 하나의 거래 ID가 부여되어 쇼핑패턴, 즉 U^m 으로 정의된다. 분석에 사용된 일부 데이터의 예는 다음 <표 2>와 같다.

4.2 쇼핑패턴의 군집

<표 2>에 나타난 쇼핑패턴의 예와같은 데이터를 이용하여 각 쇼핑패턴 U^m 간의 PPED 거리를 구하고 가장 가까운 거리의 쇼핑패턴부터 계층적으로 군집을 형성해 간다. 쇼핑 패턴간의 거리

<표 2> 쇼핑패턴 분석을 위한 데이터의 예

거래 ID	고객 ID	날짜	매장명	방문시간	날씨
1	14359	2007-06-17	행남자기	2	2
1	14359	2007-06-17	몬테밀라노	3	2
1	14359	2007-06-17	니나리찌	3	2
1	14359	2007-06-17	인스탄트	3	2
1	14359	2007-06-17	모라도	4	2
2	24826	2007-07-01	빈폴	2	4
2	24826	2007-07-01	라일앤스코트	2	4
2	24826	2007-07-01	라일앤스코트	2	4
2	24826	2007-07-01	아라미스	3	4
2	24826	2007-07-01	리베도	3	4
2	24826	2007-07-01	랄프로렌	3	4
2	24826	2007-07-01	랄프로렌	3	4
3	37720	2007-07-22	키사	2	2
3	37720	2007-07-22	보디가드	2	2
3	37720	2007-07-22	듀퐁	3	2
3	37720	2007-07-22	MU스포츠	3	2
3	37720	2007-07-22	알블루	3	2
3	37720	2007-07-22	에스까다	3	2

를 구하기 위해서는 쇼핑 패턴을 구성하고 있는 구매횟수, 구매순서, 구매개수, 날씨, 시간과 같은 다섯 가지 속성에 대한 가중치를 결정하여야 한다. 가중치는 영역 전문가에 판단에 의해 결정될 수도 있고, 실험을 통한 정확도 비교에 의해 결정될 수도 있지만, 본 논문에서는 동일 가중치를 전제로 방법론에 대한 초기 실험을 실시하였다.

쇼핑패턴의 군집 단계에서는 거리의 임계치, 즉 어느 정도의 거리까지를 유사하다고 판단할 것인지에 대한 기준을 먼저 설정해야 한다. 임계치가 낮으면 각 쇼핑패턴이 세분화 되어 보다 많은 군집이 형성되고, 임계치가 높으면 보다 적은 군집이 형성된다. 본 연구에서는 임계치를 조정하여 정확도가 높은 군집 수에 대해 분석해 보고자 한다. 각 임계치에 따른 군집의 수를 살펴보면 <그림 3>과 같다. <그림 3>에 나타난 바와 같이 쇼핑패턴의 군집수는 거리가 '3'일 때까지 급격하게 감소하다가 서서히 수렴하고 '5'이상에서는 거의 변화가 없는 것을 알 수 있다.

4.3 목표고객의 유사 군집 정의 및 추천

목표고객에게 추천할 매장들은 목표고객과 가장 유사한 군집을 찾아내고, 해당 군집에 포함된 Top N개의 매장들을 확인함으로써 이루어진다. 다시 말해, 8월에 발생한 각 고객들을 목표고객으로 정의하고 각 고객들의 구매정보 및 상황정보를 기반으로 쇼핑 패턴을 구성한 후, PPED 방법으로 군집과 목표고객의 쇼핑패턴 간의 유사도를 측정한다. 그리고 임계치를 만족하는 범위

<표 3> 군집을 생성한 목표고객의 비율

임계치	비율	
	2개 매장	3개 매장
2	0.06	0.65
3	0.00	0.45
4	0.00	0.13
5	0.00	0.00

에서 가장 가까운 군집에 포함된 Top N개의 매장들을 추천하고, 임계치를 만족하지 못할 경우에는 추천 받지 못하고, 홀로 새로운 군집을 형성하게 된다. 다음의 <표 3>은 각 임계치에 따라 독립적으로 군집을 형성하게 된 목표고객들의 비율을 나타낸다.

4.4 추천의 정확성 평가 결과

U-마켓에서는 고객의 진입 시점부터 추적하여 첫 번째 매장을 방문한 순간 추천이 이루어지지만, 이 실험에서는 수집된 백화점 데이터를 사용하므로, 실질적인 추천은 고객이 두 번째 매장을 방문한 순간부터 이루어지게 하였다. 즉, 분석을 위해서는 최소한 2개 이상의 매장을 방문해야 한다. 그리고 앞서 설명한 바와 같이 5개 이상의 매장을 포함한 쇼핑패턴을 대상으로 실험하였으므로, 추천 시점에 따라 추천 성능에 차이가 있는지 검증하기 위하여, 2개 매장을 방문했을 때, 3개 매장을 방문했을 때, 그리고 4개 매장을 방문했을 때, 순차적으로 추천하여 성능을 비교해 보았다.

모델의 추천 성능 평가를 위해 주로 사용되는 기준으로는 정확도(precision), 재현율(recall), 그리고 F1 등이 있다. 정확도는 추천한 상점 중에서 실제 고객이 방문한 상점의 비율로 정의되며, 재현율은 판매된 상점 중에서 추천된 상점의 비율로 정의된다. 그러나 두 평가 지표는 추천 상점의 수가 증가할수록 정확도는 낮아지고 재현율은 높아지는 문제점이 있다[Sarwar et al., 2000]. 따라서 식 (12)와 같이 정확도와 재현율의 조화평균(Harmonic Mean)인 F1의 기준에서 추천 성능을 평가하였다.

$$F1 = \frac{(2 \times precision \times recall)}{(precision + recall)} \quad (12)$$

먼저 고객이 2개 매장을 방문한 정보를 기반으로 추천한 결과에 대해 살펴보면 다음과 같다. 다


음의 <그림 4>는 정확도, <그림 5>는 재현율, <그림 6>은 F1 값을 측정한 것이다. <그림 4>, <그림 5>, <그림 6>에 의하면 임계치가 '3'일 때, 즉 123개 군집이 형성되었을 때 가장 높은 추천 결과가 나타난 것을 알 수 있으며, <그림 6>에 나타난 바와 같이 Top4를 추천했을 때, 즉 한번에 4개 매장을 추천했을 때, F1 값이 '0.0532'로 가장 높은 것을 알 수 있다.

다음으로 고객이 3개 매장을 방문하여 구매한 정보를 바탕으로, 추천한 결과에 대해 살펴보면 <그림 7>~<그림 9>와 같다. <그림 7>은 정확도를, <그림 8>은 재현율을, 그리고 <그림 9>는 F1 값을 측정한 결과이다. 전반적으로 살펴보았을 때, 2개 매장을 방문한 정보를 기반으로 추천했


을 때보다 높은 정확도를 보이고 있으며, 임계치 '3'일 때, 정확도가 가장 높은 것으로 나타난 것은 동일한 결과이다.

Top N에 따른 정확도 비교에서도 안정적인 추천 결과를 나타내고 있으며, <그림 9>의 정확도와 재현율을 모두 고려한 F1 값에서도 세 번째 매장 정보를 활용했을 때가 3배 이상 높은 '0.1798'로 나타났다. 즉, 고객의 쇼핑 정보가 누적됨에 따라 안정적이고 높은 정확도를 보임을 알 수 있다.

제시한 매장 추천방법과 비교하기 위하여 벡터모델을 이용한 매장 추천시스템을 구현하고, 동일한 데이터와 조건을 이용하여 분석하였다. 벡터모델의 경우에는 구매횟수 하나 만으로 쇼핑패턴 간의 유사도를 계산하기 때문에, 여러 속




<그림 4> 2개 매장 구매 정보를 이용한 추천의 정확도




<그림 5> 2개 매장 구매 정보를 이용한 추천의 재현율

성을 고려한 FM모델에 비해 쇼핑패턴간 거리, 즉 임계치가 비교적 낮다. 따라서 두 모델의 정확성을 비교해 보기 위하여 FM모델과 유사한 군집


수를 형성할 수 있도록 벡터모델의 임계치를 조정하였으며, 실험 결과는 <그림 10>과 <그림 11>과 같다. <그림 10>은 2개 매장 구매 정보를



<그림 6> 2개 매장 구매 정보를 이용한 추천의 F1 값



<그림 7> 3개 매장 구매 정보를 이용한 추천의 정확도




<그림 8> 3개 매장 구매 정보를 이용한 추천의 재현율

기반으로 추천한 결과이며, <그림 11>은 3개 매장 구매 정보를 기반으로 추천한 결과이다.


두 번의 실험 결과 모두 FM모델에 비해 군집수 및 Top N에 따라 추천 결과의 차이가 많고 불안정하게 나타나고 있다. 이는 매장의 수에 비해 구매 정보가 매우 희박(sparse)하기 때문에 나타난 결과로 추측된다. 구매 정보의 희박성(sparsity)으로 인해 빈번하게 발생하는 몇몇 매장과 관련된 쇼핑 패턴이 하나의 군집으로 집중됨으로써, 추천의 정확도가 저조하고 불안정하게 나타나는 것을 알 수 있다. 이와 같은 현상은 <그림 10>과 <그림 11>에서 모두 나타나고 있다. <그림 10>에서는 군집수 '72'개에서 Top 4의 매장을 추천했을 때, '0.0435'로 가장 높았으며, <그림

11>에서는 군집수 '56'개에서 Top 6의 매장을 추천했을 때, '0.0577'로 가장 높았다.


지금까지 실험한 FM모델과 벡터모델의 군집수 별로 가장 높은 F1 값을 비교하면 <그림 12>와 같다. FM모델과 벡터모델은 쇼핑패턴을 표현하는 방식이 서로 다르므로 각각의 임계치 또한 다르다. 즉 임계치를 기준으로 두 모델을 비교하는 것은 적절하지 않으므로, 군집의 수를 기준으로 각 모델의 정확도를 비교해 보았다. 군집의 수는 가장 많은 I에서부터 가장 적은 군집수 V까지 분류하여 비교하였으며, I은 약 200개 내외, II는 약 110개 내외, III은 약 70개 내외, IV는 약 50개 내외, V는 약 30개 내외로 군집이 형성되도록 임계치를 조정하였다. 이와 같이 비교하였을 때,




<그림 9> 3개 매장 구매 정보를 이용한 추천의 F1 값



<그림 10> 2개 매장 구매 정보를 이용한 벡터모델 추천의 F1 값



<그림 11> 3개 매장 구매 정보를 이용한 벡터모델 추천의 F1 값



<그림 12> FM모델과 벡터모델의 F1 값 비교

FM모델에서는 2개 매장 방문 정보를 기반으로 추천했을 경우, F1 값은 Top4에서 가장 높았으며, 3개 매장 방문 정보를 기반으로 추천했을 경우에는 Top6에서 가장 높았다. 그리고 벡터모델로 추천했을 경우에도 각각 Top4와 Top6에서 높았다.

FM모델을 이용한 추천방법은 임계치가 낮을 때, 즉 군집의 수가 많을 때에 비교적 높은 정확성을 보였으며, 벡터모델을 이용한 추천방법은 군집의 수가 적을 때에 비교적 높은 정확성을 보였다. 그 이유는 분석에 포함된 매장 종류가 409개로 많기 때문으로 추측된다. 즉, 고객의 매장 거래 기록만을 이용할 경우 정보의 희소성(sparsity)이 높아진다는 것이다. 따라서 벡터모델의 경우에는 군집의 수가 적을 때, 즉 군집 내에 포함된

매장의 종류가 많아짐에 따라 추천의 정확도가 높아진 반면, 상황정보를 포함한 FM모델의 경우에는 벡터모델 보다 풍부한 정보를 보유함으로써 군집의 수가 많을 때, 즉 군집 내에 포함된 매장의 종류가 적을 때 보다 정확한 추천이 이루어짐을 알 수 있었다.

FM모델과 벡터모델, 두 가지 추천방법 모두 고객의 과거 구매이력을 활용하지 않고, U-마켓을 방문한 순간 발생하는 일시적인 거래 정보만을 활용하므로 2개 방문한 매장 정보를 기반으로 추천할 매장 목록을 구성했을 경우에는 추천에 필요한 고객의 선호정보가 부족하여 정확성이 낮게 나타났다. 이 결과는 FM모델이나 벡터모델의 결과에 차이가 없음을 알 수 있다. 그러나 3개 방문한 매장 정보를 기반으로 매장을 추천하는

경우에는 벡터모델 보다 제시한 FM모델이 보다 좋은 추천 결과를 보여주고 있다.

V. 결 론

지금까지 대부분의 추천시스템 관련 연구는 인터넷 환경, 혹은 모바일 환경에서의 제품 또는 정보를 대상으로 하고 있으며, 유비쿼터스 환경에서 고객에게 적합한 매장을 추천하는 연구는 아직 부족한 실정이다. 유비쿼터스 환경에서는 날씨나 시간, 위치 등의 상황정보에 따라 같은 제품이라도 선택하는 매장이 다를 수 있으므로 고객의 상황정보를 분석하여 매장을 추천하는 것은 중요한 연구 영역으로 평가된다.

본 논문에서는 기존에 웹사용 마이닝 분야에서 개발된 FM모델을 응용하여, 유비쿼터스 환경을 기반으로 하고 있는 시장, 즉 U-마켓을 위한 매장 추천방법을 제시하였다. FM모델을 기반으로 한 매장 추천방법은 모델을 수정하지 않고도 유비쿼터스 환경에서 수집될 수 있는 다양한 정보들을 추가하여 사용할 수 있는 특징이 있다. 또한 고객에 대한 익명의 정보를 활용함으로써, 유비쿼터스 환경에서 중요도가 점차 가중되고 있는 개인 정보보호 문제 및 사생활 보호 문제를 해결하였다.

본 논문에서는 실제 백화점 데이터를 이용한 실험을 통하여, 제안한 방법론의 성능을 평가하였다. 그 결과, 구매정보 및 상황정보를 활용한 FM모델 기반의 추천 방법이 상황정보를 활용하지 않는 벡터 모델에 비해 안정적이고 정확한 추천 성능을 보이고 있으므로 유비쿼터스 환경에 적합한 추천방법이란 것을 입증하였다. 또한 고객의 쇼핑 정보가 누적됨에 따라 보다 안정적이고 정확한 추천 결과가 나타나는 것을 알 수 있었다.

현실적으로 유비쿼터스 환경 구현에 대한 제약으로 인하여, 모든 속성들을 고려하여 실험하지 못하였으며, 날씨와 같은 상황정보 또한 실시간으로 추적하기 어려우므로 기상청에서 제공한 정보로 대체하여 일별 정보를 사용하게 되었다. 이와 같은 정보 수집으로 인한 한계점은 향후 실질적인 U-마켓 환경이 구현된 후에 극복될 수 있을 것으로 기대한다. 또한 향후 연구에서는 분석에 포함된 속성들 간의 가중치를 조정하여 실험해 봄으로써, 추천의 정확성에 영향을 주는 주요 속성이 무엇인지 규명하고자 한다. 또한 추천 매장을 선택하는 기준에 대하여, 고객이 현재 위치 이외에도 고객의 현 상황정보나 해당 시점의 쇼핑패턴을 고려하는 연구를 추가적으로 실시함으로써 추천의 정확도를 높이고자 한다.

〈참 고 문 헌〉

- [1] Adomavicius, G. and Tuzhilin, A., "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions," *IEEE Transactions on Knowledge and Data Engineering*, Vol. 17, No. 6, 2005, pp. 734-749.
- [2] Al-Muhtadi, J., Ranganathan, A., Campbell, R., and Mickunas, M.D., "A flexible, privacy-preserving authentication framework for ubiquitous computing environments," *In International Workshop on Smart Appliances and Wearable Computing(IWSAWC 2002)*, pp. 771-776.
- [3] Bell, G., and Dourish, P., "Yesterday's tomorrows: notes on ubiquitous computing's dominant vision," *Ubiquit Comput*, Vol. 11, 2007, pp. 133-143.
- [4] Beresford, A., and Stajano, F., "Location pri-

- vacy in pervasive computing," *IEEE Pervasive Computing*, Vol. 2, No. 1, 2003, pp. 46-55.
- [5] Brown, P.J., Bovey, J.D., and Chen, X., "Context-aware applications: From the laboratory to the marketplace," *IEEE Personal Communications*, Vol. 4, No. 5, 1997, pp. 58-64.
- [6] Degemmis, M., Lops P., and Semeraro, G., "A content-collaborative recommender that exploits WordNet-based user profiles for neighborhood formation," *User Modeling and User-Adapted Interaction*, Vol. 17, No. 3, 2007, pp. 217-255.
- [7] Dey, A.K., "Context-aware computing: The CyberDesk project," *AAAI 1998 Spring Symposium on Intelligent Environments Technical Report SS-98-02*, 1998, pp. 51-54.
- [8] Dey, A.K., Abowd, G.D., and Wood, A., "A CyberDesk: A Framework for providing self-integrating context-aware services," *Knowledge-Based Systems*, Vol. 11, 1999, pp. 3-13.
- [9] Fano, A.E., "Shopper's Eye: Using Location-based Filtering for a Shopping Agent in the Physical World," *Proceedings of the Second International Conference on Autonomous Agents(Agents'98)*, pp. 416-421.
- [10] Hill, W., Stead, L., Rosenstein, M., and Furnas, G., "Recommending and evaluating choices in a virtual community of use," *Proceedings of CHI 1995 Conference on Human Factors in Computing Systems*, 1995, pp. 194-201.
- [11] Jang, S. and Woo, W., "ubi-UCAM: A unified context-aware application model," *Lecture Note Artificial Intelligence(LNAI)*, Vol. 2680, 2003, pp. 178-189.
- [12] Jessup, L.M. and Robey, D., "The relevance of social issues in ubiquitous computing environments," *Communications of ACM*, Vol. 45, No. 12, 2002, pp. 88-91.
- [13] Jin, X., Mobasher, B., and Zhou, Y., "A Web Recommendation System Based on Maximum Entropy," *Information Technology : Coding and Computing(ITCC)*, No. 1, 2005, pp. 213-218.
- [14] Kaufman, L. and Rousseeuw, P.J., *Finding groups in data: An introduction to cluster analysis*, New York: John Wiley and Sons., 1990.
- [15] Keegan, S. and O'Hare, G.M.P., "Easishop: Delivering Cross Merchant Product Comparison Shopping for the Mobile User," *Proceedings of the 15th IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC 2004)*, 5th-8th September Barcelona, Spain, IEEE Press.
- [16] Kim, H.K., Lee, K.J., and Kim, J.K., "A peer-to-peer CF-recommendation for ubiquitous environment," *PRIMA*, 2006, pp. 678-683.
- [17] Konstan, J., Miller, B., Maltz, D., Herlocker, J., Gordon, L., and Riedl, J., "GroupLens: Applying collaborative filtering to usenet news," *Communications of ACM*, Vol. 40, 1997, pp. 77-87.
- [18] Krulwich, B., "LIFESTYLE FINDER : Intelligent User Profiling Using Large-Scale Demographic Data," *Artificial Intelligence Magazine*, Vol. 18, No. 2, 1997, pp. 37-45.
- [19] Lemire, D., Boley, H., McGrath, S., and Ball, M., "Collaborative filtering and inference rules for context-aware learning object recommendation," *International Journal of Interactive Technology and Smart Education*, Vol. 2, No. 3, 2005, pp. 179-188.
- [20] Marco Degemmis, Pasquale Lops, Giovanni Semeraro., "A content-collaborative recom-

- mender that exploits WordNet-based user profiles for neighborhood," *User Model User-Adap Inter*, 2007. pp. 217-255.
- [21] Mehta, B., Hofmann, T., and Fankhauser, P., "Lies and propaganda: Detecting spam users in collaborative filtering," *In IUI'07: Proceedings of Intelligent user interfaces*, ACM Press, 2007, pp. 14-21.
- [22] Montaner, M., Lopez, B., and Rosa, J.L., "A taxonomy of recommender agents on the internet," *Artificial Intelligence Review*, Vol. 19, 2003, pp. 285-330.
- [23] Pazzani, M.J., "A framework for collaborative, content-based and demographic filtering," *Artificial Intelligence Review*, Vol. 13, No. 5, 1999, pp. 393-408
- [24] Ren, K., Lou, W., Kim, K., and Deng, R., "A novel privacy preserving authentication and access control scheme for pervasive computing environments," *IEEE Transactions on Vehicular Technology*, Vol. 55, 2006, pp. 1373-1384.
- [25] Rensnick, P., Iacovou, N., Suchak, M., Bergstrom, P., and Riedl, J., "GroupLens: An open architecture for collaborative filtering of netnews," *Proceedings of the Computer Supported Cooperative Work conference*, 1994, pp. 175-186.
- [26] Ryan, N.S., Pascoe, J., and Morse, D.R., "Enhanced reality fieldwork: The context-aware archaeological," *Computer Applications in Archaeology*, 1997.
- [27] Sadeh, N., Chan, T-C, Van, L., Kwon O., and Takizawa, K., "Creating an open agent environment for context-aware m-Commerce in agentcities: Challenges in open agent environments," *LNAI*, Springer Verlag, 2003, pp. 152-158.
- [28] Schafer, J.B., Konstan, J., and Riedl, J., "Recommender System in E-Commerce," *Proceedings of the ACM Conference on Electronic Commerce*, 1999.
- [29] Sarwar, B., Karypis, G., Konstan, J., and Riedl, J., "Analysis of recommendation algorithms for e-Commerce," *Proceedings of the ACM Conference on Electronic Commerce*, 2000, pp. 158-167.
- [30] Shahabi, C., and Banaei-Kashani, F., "Efficient and anonymous web-usage mining for web personalization," *Information Journal on Computing*, Vol. 15, No. 2, 2003, pp. 123-147.
- [31] Srivastava, J., Cooley, R., Deshpande, M., and Tan, P.N., "Web usage mining: Discovery and applications of usage patterns from web data," *Proceedings of the 2000 ACM SIGKDD Conference*, 2000, pp. 13-23.
- [32] Weiser, M. "The computer for the 21st Century," *Sci Am*, Vol. 265, No. 3, 1991, pp. 94-104.
- [33] Yan, T., Jacobsen, M., Garcia-Molina, H., and Dayal, U., "From user access patterns to dynamic hypertext linking," *Proc Fifth Int World Wide Web Conf on Computer Networks and ISDN*, 1996, pp. 1007-1014.

◆ 저자소개 ◆




김재경 (Kim, Jae Kyeong)

서울대학교에서 산업공학 학사, 한국과학기술원에서 경영정보시스템 전공으로 석사 및 박사학위를 취득하였으며 현재 경희대학교 경영대학 교수로 재직하고 있다. 미국 미네소타 주립대학교, 그리고 텍사스 주립대학교(달라스)에서 교환교수를 역임하였다. 주요 연구분야로는 비즈니스 인텔리전스, 추천 시스템, 유비쿼터스 서비스 등이다.



채경희 (Chae, Kyung Hee)

경희대학교에서 경영학 학사, 동 대학원에서 경영정보시스템 전공으로 경영학 석사를 취득하였으며, 박사과정을 수료하였다. 주요 연구분야로는 CRM, 데이터마이닝, e-비즈니스 모형 및 전략 등이며, 연구 결과로는 경영과학지(2004), ICEB(2004), 한국경영정보학회(2005), ISR(2006), 한국지능정보시스템학회논문지(2007) 등이 있다.



구자철 (Gu, Ja Chul)

동서대학교 경영정보학과를 졸업하고, 경희대학교 경영학과에서 석사와 박사 학위를 취득하였다. 현재 KAIST 산업및 시스템 공학과의 BK21 연구원으로 재직 중에 있으며, 관심분야로는 e비즈니스, 전자상거래, 품질경영, 지식기반시스템 등이다.

◆ 이 논문은 2008년 06월 03일 접수하여 1차 수정을 거쳐 2008년 06월 26일 게재 확정되었습니다.