

사용자 감정 예측을 통한 상황인지 추천시스템의 개선

안 현 철*

Improvement of a Context-aware Recommender System through User's Emotional State Prediction

Hyunchul Ahn*

Abstract

This study proposes a novel context-aware recommender system, which is designed to recommend the items according to the customer's responses to the previously recommended item. In specific, our proposed system predicts the user's emotional state from his or her responses (such as facial expressions and movements) to the previous recommended item, and then it recommends the items that are similar to the previous one when his or her emotional state is estimated as positive. If the customer's emotional state on the previously recommended item is regarded as negative, the system recommends the items that have characteristics opposite to the previous item.

Our proposed system consists of two sub modules-(1) emotion prediction module, and (2) responsive recommendation module. Emotion prediction module contains the emotion prediction model that predicts a customer's arousal level-a physiological and psychological state of being awake or reactive to stimuli-using the customer's reaction data including facial expressions and body movements, which can be measured using Microsoft's Kinect Sensor. Responsive recommendation module generates a recommendation list by using the results from the first module-emotion prediction module. If a customer shows a high level of arousal on the previously recommended item, the module recommends the items that are most similar to the previous item. Otherwise, it recommends the items that are most dissimilar to the previous one.

In order to validate the performance and usefulness of the proposed recommender system, we conducted empirical validation. In total, 30 undergraduate students participated in the experiment. We used 100 trailers of Korean movies that had been released from 2009 to 2012 as the items for recommendation. For the experiment, we manually constructed Korean movie trailer DB which contains the fields such as release date, genre, director, writer, and actors. In order to check if the recommendation using customers' responses outperforms the recommendation using their demographic information, we compared them. The performance of the recommendation was measured using two metrics-satisfaction and arousal levels. Experimental results showed that the recommendation using customers' responses (i.e. our proposed system) outperformed the recommendation using their demographic information with statistical significance.

Keywords : Recommender System, Emotion Prediction, Valence-Arousal Model, Content-based Method, Kinect Sensor

논문접수일 : 2014년 12월 06일 논문게재확정일 : 2014년 12월 13일

※ 이 논문 또는 저서는 2013년 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2013S1A5A2A01018410).

* 국민대학교 경영대학 경영정보학부 부교수, e-mail : hcahn@kookmin.ac.kr

1. 서 론

추천시스템(recommender system)은 소비자가 진정으로 필요로 하는 자료와 정보를 선택적으로 제공하여 정보 과부하(information overload) 현상을 해소하고, 이를 통해 소비자의 구매의사결정을 지원하는 정보시스템을 의미한다. 인터넷이 급격히 확산되기 시작한 90년대 말 이후, 추천시스템은 주요한 지능형 의사결정지원 시스템 분야의 연구주제 중 하나로 자리매김하고 있다. 특히 내용기반(content-based) 추천기법과 협동필터링(collaborative filtering) 추천기법으로 대표되는 방법론에 대한 개선 방안 연구들[김재경, 안현철, 2005; 2009; 김재경 외, 2003; 김종우 외, 2004; 조운호 외, 2004; 안현철 외, 2006]이나, 영화[Miller et al., 2003; Winoto and Tang, 2010], 음악[Kaminskas and Ricci, 2012], 관광지[Schiaffino and Amandi, 2009], 식당[Burke et al., 1996] 등 다양한 응용분야에 추천시스템을 적용하고 그 성능을 높이려는 시도들이 학계에서 활발하게 이루어져 왔다.

하지만, 추천시스템의 성능을 향상시키기 위해서는 그 무엇보다도 먼저 고객의 니즈(needs)를 정확하게 파악하는 것이 중요하다. 그 일환으로 최근 새롭게 주목 받고 있는 분야가 바로 ‘상황 인지 추천시스템(context-aware recommender system)’이다[Dao et al., 2012]. 상황 인지 접근법은 고객이 요구하기 전에 미리 고객의 니즈를 파악하여, 그들의 수요에 사전적(proactive)으로 대응하는 기법을 의미한다[Dey et al., 2001]. 상황 인지 서비스는 다양한 센서들로부터 고객의 내적 그리고 외적 상황 정보를 수집한 뒤, 이를 근거로 그들의 니즈를 추론하여, 일련의 다양한 맞춤 서비스를 제공한다[Yoo et al., 2011]. 때문에 효과적인 상황 인지 서비스를 제공하기 위해서는 사용자의 내적, 외적 상황정보를 센서를

통해 수집해야 한다. 하지만, 현실적으로 사람의 생각, 감정과 같은 내적 상황에 대한 정보 수집 및 측정은 기술적으로 제약이 많기 때문에, 지금까지는 주로 정량적으로 측정 가능한 외적 상황정보에 기반하여 연구가 수행되어 왔다[Dao et al., 2012; Kwon, 2003; Yang et al., 2008].

이러한 배경에서 본 연구는 사용자, 즉 고객의 내적 상황정보, 그 중에서도 고객의 감정 상태를 파악하여, 이를 통해 실시간으로 고객의 니즈 변화에 대응하는 새로운 개념의 추천시스템을 제안하고자 하였다. 구체적으로 본 연구는 고객이 경험 중인 제품이나 서비스에 대해 표출하는 반응(얼굴표정과 움직임)을 센서로 감지하여, 그 변화를 토대로 해당 고객이 어떤 감정을 느끼는지 추정하고, 추정된 감정의 결과가 긍정적인지 혹은 부정적인지의 여부를 파악해 그 다음 추천 아이টে를 결정할 때 활용하는 추천 알고리즘을 설계하고자 하였다. 즉, 본 연구는 2개의 소주제(감정 예측, 추천시스템)가 하나로 융합된 지능형 정보시스템의 개발을 다루고 있다고 할 수 있다.

본 논문의 뒷부분은 다음과 같이 구성된다. 우선 제 2장에서는 본 연구에서 상황인식 추천시스템과 관련한 이론적 배경과 기존 연구들을 살펴보고, 제 3장에서는 본 연구에서 제안하는 추천시스템의 전체적인 구성 체계를 소개한다. 제 4장에서는 실제 데이터에 기반하여 제안 추천시스템을 구축하고, 그 성능을 검증하는 과정이 설명된다. 마지막 제 5장에서는 본 연구의 학술적, 실무적 시사점과 함께, 후속 연구를 통해 극복해야 할 한계점들이 제시될 것이다.

2. 이론적 배경

앞서 서론에서 소개한대로, 본 연구에서는 감정 예측과 추천시스템이 결합된 새로운 형태의

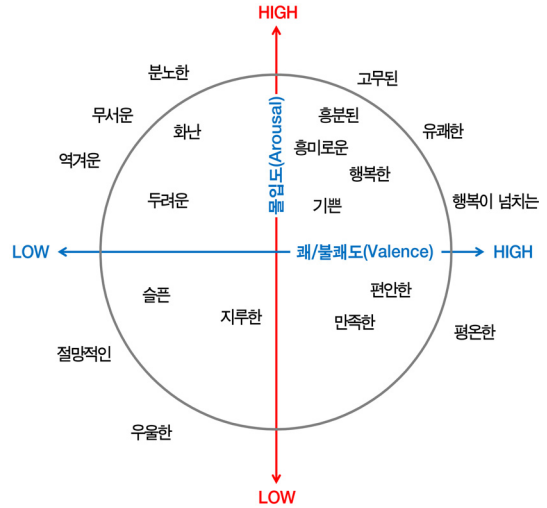
지능형 시스템을 제안하고 있다. 이에 이론적 배경을 살펴보고자 하는 본 장에서는 감정 예측과 추천시스템에 관한 이론적 배경과 최신 연구동향을 살펴본다.

2.1 감정 예측

인간의 감정을 계량적으로 측정하고, 예측하기 위해서는 우선 감정을 체계적으로 분류할 수 있는 적절한 틀이 요구된다[김성진 외, 2012; 유은정 외, 2013; 이기천 외, 2014]. 이러한 감정의 분류체계에 대한 연구는 심리학 분야에서 오래 전부터 활발하게 이루어져 왔는데, 그 중 가장 널리 활용되고 있는 체계 중 하나로 Ekman [1972]의 6가지 감정분류 체계를 들 수 있다. 이 체계에서는 인간의 기본 감정을 놀람(surprise), 공포(fear), 혐오(disgust), 화남(anger), 행복(happiness), 슬픔(sadness)의 6가지로 분류하고, 인간의 모든 감정들이 이 6가지 기본 감정들의 조합으로 표현될 수 있는 것으로 보았다[김성진 외, 2012].

한편 Russell[1983]은 모든 인간의 감정 상태를 2차원 공간에 계량화 시킬 수 있는 V-A(Valence-Arousal) 모형을 제시하였다. 이 모델에서 감정은 교차하는 두 축을 기반으로 좌우는 쾌/불쾌(valence), 상하는 몰입(arousal)의 강도에 따라 계량화 될 수 있다. 다음 <그림 1>은 감정을 표현하는 각종 형용사들이 V-A 모형의 2차원 평면에서 어떻게 배치되는지 나타내고 있다.

앞서 소개한 Ekman[1972]의 분류체계의 경우, 6개의 기본 감정 중 행복을 제외하고 모두 부정적인 감정들뿐이라 경영 분야에서 효과적으로 활용하는데 있어 상당히 많은 제약을 안고 있다[정민규, 김재경, 2012; Brainerd et al., 2010; Nicolaou et al., 2011]. 때문에 오늘날 감정 예측을 응용하고자 하는 대부분의 연구들이 V-A



<그림 1> V-A 감정분류 모형

모형을 기반으로 연구를 수행하고 있다[김성진 외, 2012; 이기천 외, 2014; 정민규, 김재경, 2012; Nicolaou et al., 2011 등].

V-A 모형을 기반으로 사람의 반응을 활용해 감정을 예측하고자 하는 연구가 국내외에서 최근 활발하게 발표되고 있다. 예를 들어, Nicolaou et al.[2011]은 얼굴표정과 어깨움직임, 그리고 소리를 활용해 BLSTM-NNs(the bidirectional Long Short-Term Memory neural networks), SVR (Support Vector Regression) 등의 기법을 이용해 감정을 예측하는 모형을 제안하였고, 정민규와 김재경[2012]은 자극을 받았을 때 나타나는 사용자의 얼굴 표정 변화를 기반으로 감정을 예측할 수 있는 인공지능 기반의 모형을 제시하였다. 김성진 외[2012]는 정민규와 김재경[2012]의 연구를 한 단계 더 발전시켜, SVR을 이용해 예측 정확도를 개선할 수 있는 모형을 제시하였으며, 이기천 외[2014]의 연구에서는 Microsoft 키넥트 센서를 이용해 사용자의 얼굴표정 외에 움직임까지도 파악하고, 이를 시계열 데이터로 분석하여 보다 정교한 감정 예측을 가능케 하는 모형을 발표하였다.

2.2 추천시스템

최근 인터넷을 기반으로 한 고객관계관리, 즉 e-CRM에 대한 기업들의 관심이 크게 확대되면서, 특정 고객에게 그가 관심을 가질만한 제품이나 서비스를 선별하여 추천해 주는 추천시스템(recommender system)에 대한 활용도 크게 늘고 있다. 기업들이 추천시스템에 관심을 갖고 투자하는 이유는 크게 다음의 3가지로 요약된다.

우선 첫째는 추천시스템이 정보 과부하(information overload) 문제를 해결해 줄 수 있기 때문이다[Schafer et al., 2001]. 오늘날 전자상거래 시장이 크게 성장하면서, 업체들이 취급하는 제품의 수도 크게 늘어나고 있는 추세이다. 예를 들어, ‘장난감(toy)’이라는 키워드로 취급 상품을 검색¹⁾해 보았을 때, amazon.com의 경우 385만여 개, ebay.com의 경우 약 290만 개의 상품이 조회된다. 국내 오픈마켓의 경우도 크게 다르지 않은데, 옥션(auction.co.kr)에서 163만여 개, G마켓(gmarket.co.kr)에서 약 46만 개, 11번가(11st.co.kr)에서는 약 316만여 개의 상품이 검색된다. 이렇게 과도하게 많은 수의 상품이 존재하기 때문에, 개인의 취향을 고려해 고객에게 적합한 정보만 정제(filtering)하여 보여 줄 수 있는 추천시스템은 ‘정보 과부하’ 문제의 효과적인 대안이 될 수 있다.

둘째로, 추천시스템은 대중 맞춤(mass customization)을 실현하는 가장 현실적인 대안인다는 측면에서 의의를 지닌다[Schafer et al., 2001]. 본래 Pine에 의해 지난 1993년 처음 제안된 대중 맞춤이라는 개념은 “수많은 고객들 개개인의 욕구를 충족시킬 수 있는 맞춤 상품 혹은 서비스를 제공하는 것”이었지만[Pine, 1993], 이는 실제 물리적인 생산 환경의 제약 문제로 인하여 지금까지 이상적인 상태(ideal state)로

만 취급되어 온 것이 사실이다. 하지만 추천시스템은 비록 ‘수많은 고객들 개개인의 욕구를 충족시킬 수 있는 맞춤 상품이나 서비스’를 직접 창조해 내는 것은 아니지만, 수많은 상품이나 서비스들 중에서 개개인의 상황에 적합한 것만 골라서 보여준다는 측면에서, 대중 맞춤을 실현하는 가장 현실적인 대안으로 평가되고 있다.

마지막으로, 추천시스템은 판매자와 구매자 모두에게 가치를 제공한다는 이유로도 오늘날 널리 환영 받고 있다. 우선 판매자의 경우, 추천시스템을 통해, (1) 단순히 쇼핑몰을 둘러보는 고객들을 실질적인 구매자로 유도할 수 있고, (2) 교차 판매(cross-selling)나 상승 판매(up-selling)를 증대시킬 수 있으며, (3) 고객의 충성도(loyalty)를 향상시킬 수 있다[Schafer et al., 2001]. 한편, 구매자는 추천시스템과 같은 맞춤 마케팅 도구를 사용할 경우, 비용 절감 및 만족 증대와 같은 실질적인 효과를 얻을 수 있다[Haubl and Trifts, 2000].

추천시스템을 구현하는 추천 알고리즘의 접근법은 크게 2가지로 구분된다. 우선 첫 번째 접근법은 ‘내용기반 접근법’이다. 이것은 방문객에게 해당 방문객이 전에 선호했던 아이템과 가장 유사한 특성을 가진 아이템을 추천하는 방식으로서, 아이템간 연관성을 기반으로 추천을 하는 방식이다. 또 다른 접근법은 ‘협동 필터링 접근법’이다. 이것은 앞서 내용기반 접근법이 아이템 간의 연관성을 기반으로 추천결과를 생성하는 것과 달리, 사용자 간 연관성을 기반으로 추천결과를 생성하는 방식인데, 방문객과 유사한 선호체계를 가진 다른 사용자들이 과거에 선호한 아이템 중 방문객이 아직 경험해 보지 못한 아이템을 선별해 추천하는 방식이다[안현철 외, 2006; Funakoshi and Ohguro, 2000]. 이 두 접근법 중에서, 오늘날 협동필터링이 더 활발하게 이용되고 있지만, 협동필터링은 데이터가 충

1) 2014년 11월 28일 기준.

분히 축적되어 있지 않은 상황에서 작동되기 어려운 문제(cold-start problem), 데이터가 너무 과도하게 많을 경우 연산시간이 과도하게 소요되는 문제(scalability problem) 등의 문제가 있어 상황에 따라 내용 기반 접근법을 사용하거나, 두 기법이 혼합(hybrid)된 접근법을 사용하기도 한다[김재경 외, 2002, 2005; 김종우 외, 2004; 조윤희 외, 2004 참고].

2.3 상황인지 추천시스템

상황인지 추천시스템(context-aware recommender system)은 기존의 추천시스템에 상황인지 기술을 접목시킨 것으로 최근 추천시스템 연구 분야 중 가장 높은 관심을 받는 분야 중 하나이다[Adomavicius et al., 2005]. 일반적으로 사용자의 관심사는 안정적으로 유지되는 편이지만, 각 개별 아이템에 대한 평가는 매 순간 다양한 외부 환경 변수에 의해 영향을 받을 수 있다. 때문에, 동일한 아이템이라고 하더라도 해당 아이템을 소비하는 시점의 상황이 어떠한가에 따라 전혀 다른 고객경험을 제공할 수 있다 [Anand and Mobasher, 2005]. 이러한 배경에서, 상황인지 추천시스템에서는 사용자가 처한 상황을 인지하여, 보다 나은 추천이 이루어지도록 하는 것을 목표로 한다.

예를 들어, Si et al.[2005]는 전통적인 협동 필터링 기법에 사용자의 시시각각 변화하는 상황 정보(예: 시간, 장소, 외부환경 등)를 추가로 고려하여, 사용자가 방문해 보지 못했던 상점이나 사용자가 선호할만한 콘텐츠를 추천할 수 있는 새로운 시스템을 제안하였다. 이들의 연구는 단순히 시스템의 원리를 이론적으로 제시하는데 그치지 않고, 실제 구현을 통해 유용성을 검증했다는 측면에서 의의가 있지만, 정보를 수집하는데 사용자가 자신의 신체에 연구진이 자체

제작한 특수 센서를 착용해야 한다는 점에서 연구의 성과가 범용적으로 확대 적용되기엔 한계가 있다.

한편 Lemire et al.[2005]도 전통적인 협동 필터링에 상황인지를 할 수 있는 추론 규칙을 접목시켜, 보다 개인화 된 추천을 가능케 하는 새로운 상황인지 추천방법을 제안하였다. 이들의 모형은 그 작동원리가 논문에서 상세히 기술되었지만, 실제적인 구현과정이 생략되어 있어 실증적으로 모형의 유용성이 검증되지는 못했다는 치명적인 한계를 갖고 있다.

Chen[2005]과 Dao et al.[2012] 역시 상황인지가 결합된 협동 필터링 방법을 제안하였다. 이 연구들은 협동 필터링으로 추천을 할 때, 기존의 상황과 현재 사용자가 처해있는 상황이 얼마나 유사한 지 상황유사도(context similarity)를 계량적으로 산출해, 그 결과를 추천 결과 도출시 참조할 수 있도록 설계하였다. Chen[2005]의 경우, 방법론만 제시하고 실증분석을 통한 검증은 이루어지지 못했다는 한계점이 있지만, Dao et al.[2012]은 지역광고 데이터에 적용한 실증분석을 통해 상황유사도를 반영했을 때 그렇지 않을 때보다 예측성과의 개선이 있음을 확인하였다.

이처럼 상황인지 기술을 추천시스템과 접목하고자 한 기존 연구들은 대부분 협동필터링과의 결합을 시도하고 있으며, 공통적으로 상황을 정의할 때 계량화가 용이한 가시적인 요인들(시간, 위치, 온도, 각종 인구통계 정보 등)만 고려하고 있다는 한계가 있다. 본 연구와 비슷하게 심리학의 기본 이론들을 기반으로 인간의 감정을 모델링하고, 이를 추천시스템이나 개인화 서비스와 연계하려는 연구는 Hsieh[2011]를 제외하고 거의 찾아보기 힘들다. Hsieh[2011]는 사용자의 감정과 추천시스템을 연계를 처음으로 시도하였다는 점에서 학술적으로 의의가 있다.

하지만, 감정의 모델링이 단순하고, 그 예측이 사용자의 설문에 의존하게끔 설계되어 있다는 점에서 치명적인 한계가 있다.

3. 제안 시스템 구성 체계

본 연구는 사용자의 반응을 기반으로 해당 사용자의 감정을 예측하고, 그 결과를 바탕으로 상품추천 결과를 변화시키는 상황인지 추천시스템을 새롭게 제안한다. 본 연구에서 제안하는 시스템의 구성 체계(architecture)를 다음 <그림 2>에 제시하였다. 이 그림에 제시된 바와 같이 본 연구의 제안 시스템은 크게 2개의 모듈로 구성되는데, 각 모듈은 서로 밀접하게 연계되어 있으나, 사실상 독립된 소주제를 다루고 있다고 해도 무방하다.

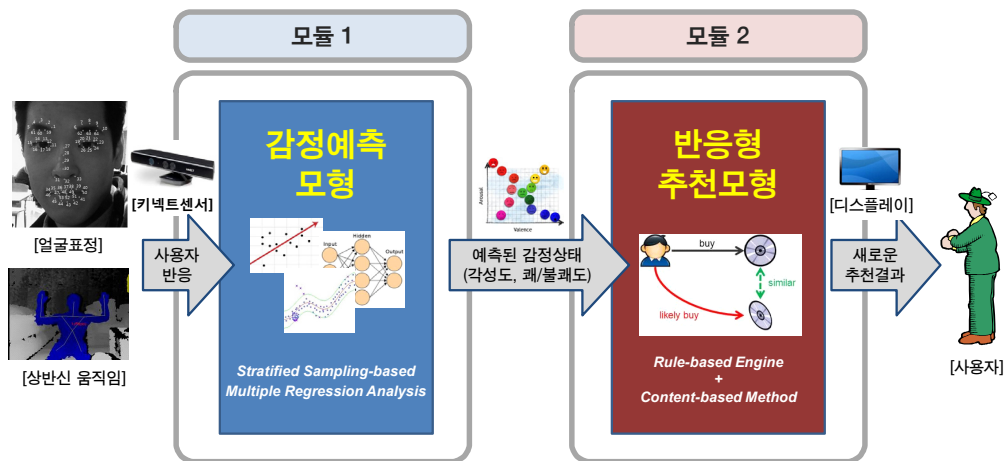
각 모듈을 구성하는 감정 예측모형과 상품추천모형의 기능과 특성을 좀 더 상세히 살펴보면 다음과 같다.

3.1 감정 예측모형

감정 예측모형은 제공 중인 자극에 대한 사용자의 반응정보, 즉 사용자의 얼굴표정 및 상

반신 움직임 등을 측정하고, 이를 기반으로 해당 사용자의 감정 상태를 계량적으로 예측·평가할 수 있는 모형을 의미한다. 이러한 감정 예측모형을 구축하기 위해서는 우선 인간의 감정을 체계적으로 분류하고, 측정할 수 있도록 하는 적절한 틀이 요구된다. 본 연구에서는 오늘날 대부분의 감정 모델링 연구들이 채택하고 있는 V-A 모형을 기반으로 감정 예측을 수행하도록 한다.

한편 감정 예측모형의 입력변수(독립변수)로 본 연구에서는 얼굴 표정과 상반신의 움직임을 사용하기로 하였다. 기존 연구들에 따르면, 인간의 감정을 예측하는데 활용 가능한 입력신호로 얼굴 표정, 소리(특히 말), 움직임, 그리고 심박수, 피부전도도와 같은 생체신호 등이 있다[고광은, 심귀보, 2009; 박재언 외, 2010; 최아영, 우운택, 2005; Nicolaou et al., 2011; Wong and Cho, 2009 등]. 이 중, 생체신호의 경우, 몸에 부착하는 특별한 센서를 장착해야 하기 때문에 현실적으로 적용하기에 어려움이 있고, 소리의 경우에도 장소에 따라 아예 소리를 낼 수 없거나(예. 박물관이나 전시관), 소리를 낼 수 있다고 해도 잡음이 많이 섞일 수 밖에 없는 실외 환경의



<그림 2> 제안 시스템의 구성 체계

경우, 적용에 심한 제약이 따르기 때문에 본 연구의 입력변수로는 적합하지 못하다. 이러한 배경에서 본 연구는 얼굴표정과 상반신 움직임의 변화를 입력변수로 최종 설계하였는데, 이 두 가지 신호는 최근에 출시된 Microsoft의 키넥트 센서(Kinect Sensor)를 사용하면 한꺼번에 손쉽게 측정이 가능하다.

결국 본 연구의 감정 예측모형은 키넥트 센서로부터 입력된 얼굴표정과 상반신 움직임 변화로부터 해당 사용자의 쾌/불쾌도와 몰입도(V-A)를 예측할 수 있는 모형이 되어야 한다. 이렇게 사용자의 반응정보를 기반으로 감정 상태를 예측하는 알고리즘으로 본 연구에서는 가장 최근에 발표되었고, 또 가장 우수한 성능을 가진 것으로 검증된 이기천 외[2014]에서 제안된 방법론을 적용하기로 하였다. 이기천 외[2014]는 총화추출에 기반한 다중회귀분석을 이용해 시계열 감정 상태를 예측하는 모형을 제안하였는데, 통계에 기반한 안정적인 모형이고 기존 방법들과 비교해 예측정확도도 높은 것으로 검증된 기법이므로 이를 채택하기로 하였다.

3.2 반응형 추천모형

모듈 2를 구성하는 반응형 추천모형은 앞서 모듈 1을 통해 산출된 사용자의 감정상태 예측결과를 토대로, 적절한 상품추천결과를 생성하거나 이미 노출되고 있는 추천결과를 수정·보완하는 기능을 담당한다. 반응형 추천모형으로 본 연구에서는 규칙 기반 시스템(rule-based system)과 내용 기반 접근법이 결합된 방식을 적용한다.

앞서 설명한 바와 같이, 모듈 1의 감정 예측모형은 사용자의 몰입도와 쾌/불쾌도에 대한 예측값을 모듈 2에 제공하게 된다. 이 때, 사용자의 몰입도도 일정 수준 이상으로 측정되고, 쾌/

불쾌도 역시 유쾌한 방향으로 감지된다면 이는 해당 사용자가 현재 노출되고 있는 자극 혹은 추천결과에 상당히 만족해하고 있는 것으로 해석할 수 있다. 때문에, 이 경우에는 현재 노출 중인 아이템과 유사한 아이템을 추천하는 것이 전략적으로 유리하다. 반면, 사용자의 몰입도가 낮은 것으로 측정되고, 쾌/불쾌도 역시 유쾌하지 않은 것으로 감지된다면, 이는 사용자가 현재 노출 중인 아이템에 매력을 느끼지 못했거나, 관심이 없는 것으로 해석할 수 있다. 그래서, 이 경우에는 현재 노출 중인 아이템과 정반대의 특징을 가진 아이템을 새로 추천해 보는 것이 전략적으로 타당하다.

본 연구의 모듈 2에서는 앞서 설명한 것과 같은 논리를 ‘IF-THEN 형태의 규칙’으로 탑재하여, 적절한 추천이 구현될 수 있도록 한다. 그리고, 규칙이 발동(trigger) 되었을 때, 현재 노출 중인 아이템과 가장 유사한, 혹은 가장 반대인 아이템을 찾기 위해, 본 연구에서는 ‘내용기반 추천기법’을 응용한다. 제 2.2절에서 소개한 것처럼 내용기반 추천기법은 사용자가 이전에 선호했던 아이템과 가장 유사한 아이템 중 내가 경험해 보지 못했던 것을 추려내 추천하는 원리로 작동되는데, 이렇듯 내용기반 추천기법에는 추천 대상이 되는 아이템 간 유사도를 측정할 수 있는 방법이 반영되어 있기 때문에 본 연구의 모듈 2를 구현하는데 있어 그 기본 원리가 유용하게 활용될 수 있다.

4. 제안 시스템 구현 및 검증

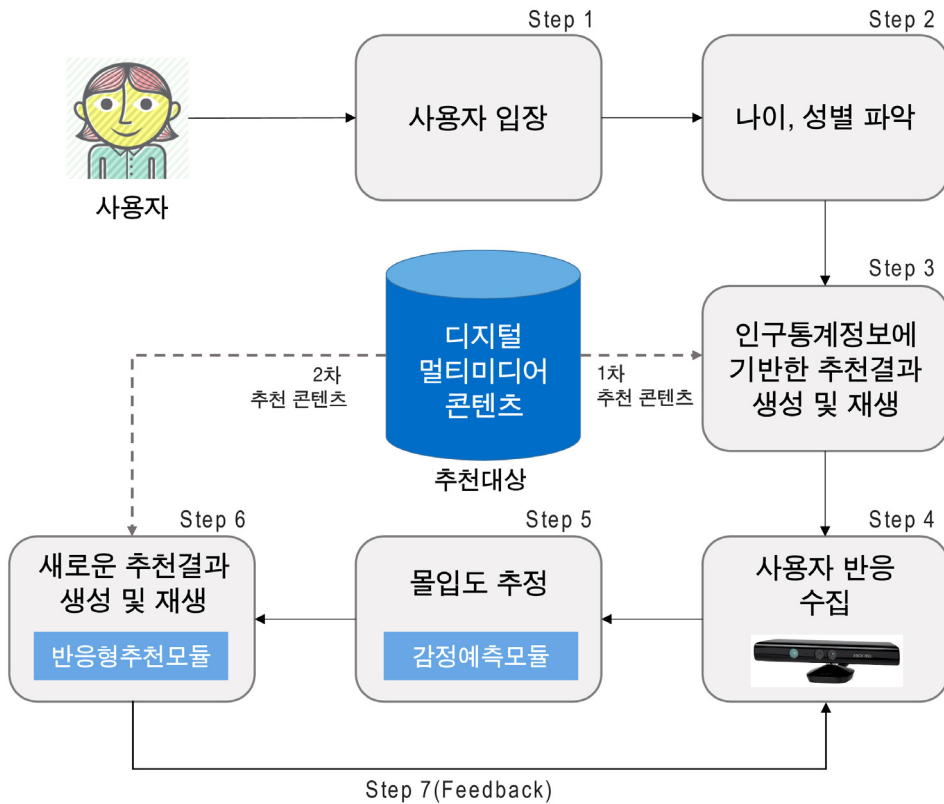
앞서 제안한 상황인지 추천시스템을 실제로 프로토타입 형태로 구현해 보고, 그 성능을 검증해 보기 위해 본 연구에서는 ‘디지털 멀티미디어 콘텐츠’에 대한 상황인지 추천시스템을 실제로 구현하는 작업을 수행하였다.

이번 연구에서 시범적으로 구현된 멀티미디어 콘텐츠 상황인지 추천시스템(Multimedia Contents Context-aware Recommender System, 이하 MCCRS)은 한국영화 예고편을 대상으로 하여, 사용자에게 적합할 것으로 예상되는 콘텐츠를 우선적으로 추천하여 보여준 뒤, 해당 사용자가 시청 중 보이는 반응을 분석하여 차후에 추천할 콘텐츠를 보다 정교화 할 수 있도록 구현되었는데, 이 때 앞의 제 3장에서 설명한 감정 예측모듈과 반응형 추천모듈이 적절히 활용될 수 있게끔 하였다. 다음의 <그림 3>은 MCCRS의 전반적인 구조 및 작동 프로세스를 나타내고 있다.


MCCRS의 일곱 단계 작동 과정을 좀 더 상세히 살펴보면 다음과 같다. 우선 1단계에서 사용자가 입장하여 추천시스템 앞에 다가서거나

착석하게 되면, 2단계에서 해당 사용자의 얼굴 화상을 활용해 연령대와 성별을 추정하게 된다. 얼굴 화상을 활용해 연령대와 성별을 판독하는 기술은 본 연구에서 당초 계획했던 연구범위를 벗어난 기능이므로, 본 연구에서는 Olaworks라는 기업에서 보유하고 있는 상용 기술을 도입해 사용하였다.


이렇게 연령대와 성별이 파악되면, 3단계에서는 특정 연령층과 성별에서 가장 선호된 콘텐츠를 1차 추천 콘텐츠로 불러와 재생하게 된다. 그렇게 되면, 사용자는 해당 콘텐츠를 보면서 얼굴표정과 몸짓으로 반응을 보이게 되는데, 해당 반응은 4단계에서 키넥트 센서를 통해 실시간으로 수집되게 된다. MCCRS에서는 다음 <그림 4>에 제시된 것과 같이, 총 121개의 2차원



<그림 3> MCCRS의 전반적인 구조 및 작동 프로세스



(a) 121개의 얼굴 특징점



(b) 10개의 신체 상반신 특징점

〈그림 4〉 키넥트 센서가 측정하는 사용자 반응

(X, Y) 얼굴 특징점과 10개의 3차원(X, Y, Z) 신체 상반신의 특징점을 키넥트 센서로 측정하게 되는데, 이는 결과적으로 매 프레임마다 총 272개($121 \times 2 + 10 \times 3$)의 변수를 측정하는 셈이 된다. 본 연구에서 키넥트 센서는 매 초당 30프레임씩 측정하도록 설계되어 있어, 상당히 방대한 양의 사용자 반응이 데이터로 축적되게 된다.

5단계에서는 이렇게 키넥트 센서를 통해 측정된 값을 사용해 감정 예측모듈이 해당 사용자의 콘텐츠에 대한 감정반응상태를 추정하게 되는데, MCCRS는 여러 감정의 유형 중에서 ‘몰입도’만을 예측하도록 최종 설계되었다.

제 3.2절에서 설명한 바와 같이 본래는 ‘몰입도’와 ‘쾌/불쾌도’를 동시에 예측하여, 이들을 모두 새로운 추천결과를 생성하는데 활용할 계획이었다. 하지만, 영화 예고편과 같은 멀티미디어 콘텐츠의 경우 제작자가 의도적으로 불쾌한 감정(공포, 슬픔)을 유발하는 경우가 많아, 콘텐

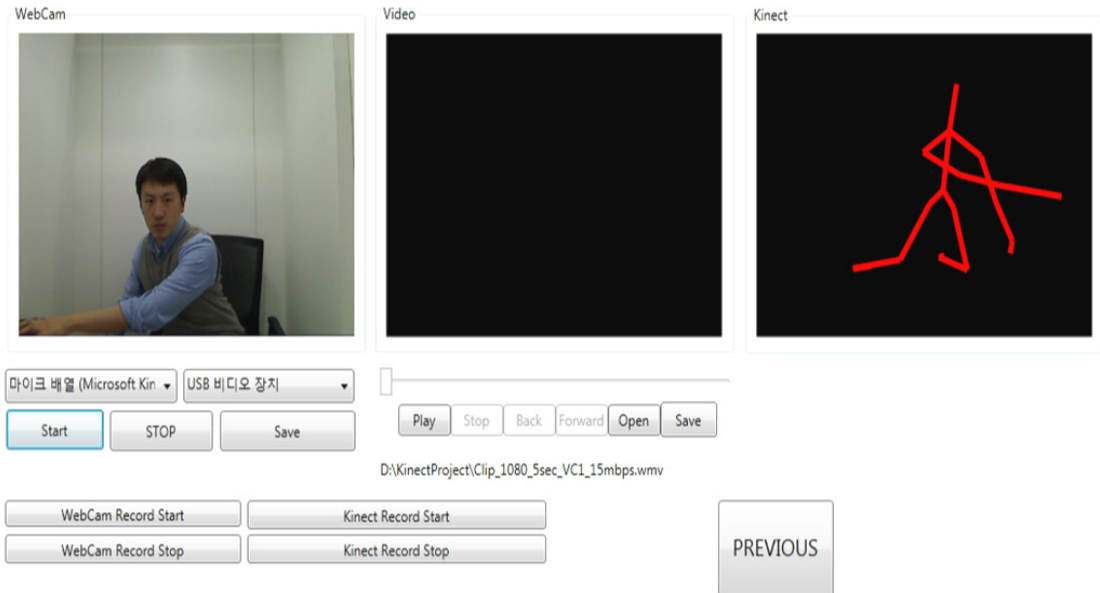
츠에 대한 반응이 불쾌하게 나왔다고 해서 부적절한 추천결과가 생성되었다고 해석하는 것은 적절치 않다는 문제가 있었다. 이에 본 연구의 검증과정에서는 V-A 모형의 2가지 차원 중 몰입도만을 예측하여, 이를 바탕으로 현재 재생 중인 콘텐츠가 사용자에게 적합한 지 아닌지의 여부를 판단하게끔 하였다.

이렇게 1차 추천된 콘텐츠에 대한 몰입도가 추정되고 나면, 6단계에서는 이 몰입도가 기준값 이상인지, 이하인지를 판단하여 새로 추천할 콘텐츠를 결정하게 된다. 기준값 이상일 경우, 앞서 재생된 콘텐츠에 대한 관심이 있다는 방증이므로 ‘반응형 추천모듈’이 이전 콘텐츠와 가장 유사한 콘텐츠를 찾아 재생하게 된다. 반면, 기준값 이하로 나올 경우, 이전에 재생된 콘텐츠가 흥미롭지 못했다는 것을 의미하므로, 이 경우에는 ‘반응형 추천모듈’이 이전 콘텐츠와 가장 상이한 콘텐츠를 찾아 재생하게 된다. MCCRS에서 몰입도는 -1에서 1사이의 값으로 측정되어 있어, 기준값으로는 0을 사용하였다. 아울러, 이전에 재생된 콘텐츠와 가장 유사한, 혹은 가장 상이한 콘텐츠를 찾아내는 알고리즘으로는 전통적으로 많이 사용되어 온 ‘내용 기반 추천법’을 사용하였다.

이렇게 새로운 추천 아이템이 결정되어, 2차 추천 콘텐츠가 사용자에게 제공되면, 사용자는 또 그에 대해 반응을 보이게 될 것이다. 그러면 이는 다시 키넥트 센서에 의해 측정되어, 그 다음 번 추천결과를 생성하는데 사용되게 되며, 이 같은 피드백 활동은 사용자가 추천시스템 이용을 중지할 때까지 지속적으로 반복된다.

4.1 감정 예측모듈의 구현

감정 예측모듈의 구현을 위해 본 연구에서는 키넥트 센서와 PC, 그리고 대형 TV가 설치된 실



〈그림 5〉 얼굴 및 신체 특징점 기록을 위한 실험시스템 화면

험 환경을 구축하였다. 그런 다음 국내 벤처기업인 (주)모전스랩의 기술협조를 얻어, <그림 5>와 같은 실험 시스템을 제공받아 감정 예측모델 구현에 요구되는 기초데이터들을 수집하였다. 모전스랩의 실험 시스템은 피실험 대상자에게 적절한 자극 동영상을 보여주고, 이 때 반응으로 나타나는 120여 개의 얼굴 특징점과 얼굴, 어깨, 목 등 총 10개 신체 특징점의 위치 변화를 XML 데이터로 초당 수십회 이상 기록할 수 있도록 설계되어 있다. 또한 종속변수인 피실험자의 감정 상태 역시, 시간 흐름에 따라 어떻게 변화하는지를 연속적으로 기록할 수 있는 기능이 탑재되었는데, 이는 영국 Queen's University Belfast의 심리학부 연구팀에서 개발한 Feeltrace 시스템을 참조해 개발되었다. Feeltrace는 피실험자의 감정 상태를 V-A 모형에 따라 2차원으로 기록할 수 있도록 하는 소프트웨어로서, 현재 누구나 활용할 수 있도록 공개²⁾되어 있다.

상기 실험시스템을 통해, 전원 20대로 구성된 총 17명의 피실험자에게 다양한 감정을 유발하도록 설계된 약 23분 분량의 자극 동영상을 틀어주고, 그들의 얼굴표정 및 신체 상반신 움직임 반응을 측정하였다. 그런 다음, 자극 동영상과 본인이 반응했던 녹화 영상을 함께 틀어주면서, 자극 노출 당시 본인이 느꼈던 감정상태(몰입도 및 쾌/불쾌도)를 직접 Feeltrace를 활용해 입력하도록 하여, 종속변수로 활용할 감정 상태에 대한 데이터를 획득하였다. 그 결과 총 602,599건의 데이터를 확보할 수 있었으며, 이를 기반으로 몰입도를 예측할 수 있는 모형을 개발해 추천시스템에 활용하고자 하였다.

본 연구에서 몰입도 예측 모형 개발에 사용한 방법은 층화 추출(stratified sampling)에 기반한 다중회귀분석 모형이다. 본 연구에서는 수집된 입력 변수 $X(602599 \times 272)$ 와 결과 변수 $Y(602599 \times 1)$ 로부터 피실험자를 기준으로 작은 집단을 만들어 계층화된 샘플링을 수행하여 X, Y 를 대표하는 표본을 만들었다. 구체적으로, 역행렬 계산 시간을

2) <http://www.dfki.de/~schroed/feeltrace/>.

고려해 1회 표본 집합을 0.01%로 하여 관측치(n)가 6,025가 되게 하고, 이 표본 집합을 $B = 10,000$ 회 만들어서 다중회귀분석을 수행하였다.

다중회귀분석은 단순회귀분석이 확장된 것으로, 독립변수가 두 개 이상인 회귀분석을 의미한다. 종속변수 Y 를 설명하기 위해 k 개로 이루어진 독립변수 x_1, x_2, \dots, x_k 를 도입한다고 할 때, 다중회귀모형은 다음과 같이 정의된다.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$


여기서 $\beta_1, \beta_2, \dots, \beta_k$ 는 추정되어야 할 회귀계수들을 의미하며, ϵ 는 오차항으로서 서로 독립이면서 동시에 동일한 분포 $N(0, \sigma^2)$ 을 따른다. 최소자승방법(Least Squares Method)에 의하여 회귀 변수 $[\beta_1, \beta_2, \dots, \beta_k] = \beta$ 는 다음과 같은 방법으로 구해진다.

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

이 과정에서 $(X^T X)^{-1}$ 를 계산해야 하는데, 행의 수가 커지면(예를 들어, 8,000개) 긴 계산 시간이 필요하게 된다. 이러한 이유로 본 연구에서는 1회 표본 집합을 0.01%(= 6,025개)로 한정해 계층화 샘플링하여 X, Y 행렬을 대표할 수 있게 만들고, 이 과정을 많은 횟수($B = 10,000$) 반복함으로써 안정적인 예측 모형을 산출하고자 하였다. 그런데, 이 과정에서 전통적인 다중회귀분석이 풀어야 할 몇 가지 문제들이 발생한다.

첫 번째 문제는 다중공선성(multicollinearity)이다. 다중회귀분석에서는 설명변수(독립변수)들 간에 서로 종속되어 있는 경우가 발생할 수 있는데 이것이 다중공선성이다. 다중공선성은 추정된 회귀식을 불확실하게 하고, 예측에 사용할 수 없게 한다. 본 연구는 이 문제를 다음의 방법으로 해결하였다. 입력 데이터 행렬 X 에서 x_k ($k = 1, \dots, 272$)를 각각 제외하면서 만들어진 행


렬인 X_{-k} 의 랭크(rank)를 계산하여 $\text{rank}(X)$ 와 $\text{rank}(X_{-k})$ 를 같게 하는 x_k 를 찾아낸다.



〈그림 6〉 Rank(x_{-k}) 분석 결과

기존 입력 $\text{rank}(x)$ 가 269이므로, 위의 <그림 6>에서 보듯이, 269와 같게 하는 다섯 개의 변수 $x_{35}, x_{36}, x_{101}, x_{219}, x_{220}$ 를 제외한다. 그리하여 최종적으로 272개에서 5를 뺀 267개의 변수를 독립변수로 고려하였다.

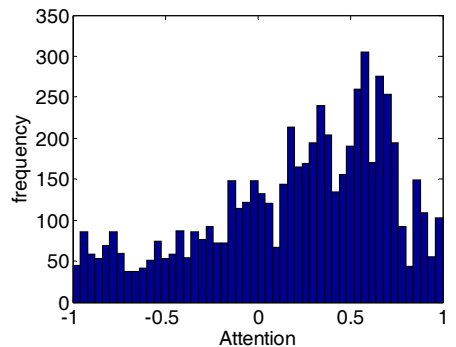



두 번째 문제는 독립변수들($x_k, k = 1, \dots, 272$)의 측정척도(scale) 영향력 차이로 인한 문제이다. 각 변수값의 측정척도가 다르기 때문에 특정 변수가 다중회귀모형에 과도하게 영향을 미치는 위험이 발생할 수 있다. 다음의 <그림 7>에서 보듯, 신체 상반신 움직임을 나타내는 x_k ($k = 1, \dots, 30$)의 변수들의 표준편차가 나머지 변수들보다 크게 작음을 확인할 수 있다. 이에 본 연구에서는 Z -변환($\frac{x_k - \mu_k}{\sigma_k}$)을 통하여 모든 입력 변수들의 표준편차가 1이 되도록 정규화하였다. 여기서 μ_k 는 x_k 의 평균이며 표본 평균으로 예측하여 사용하였고, σ_k 는 분산이며 표본 분산을 이용하여 예측하였다. 계층화 샘플을 사용하고 있으므로 표본 평균과 표본 분산을 누적하여 전체 표본 평균과 분산을 예측하였다.



<그림 7> σ_k 분석 결과

세 번째 문제는 변수선택방법의 문제이다. 하나의 종속변수를 설명하는 독립변수들의 조합으로 만들어지는 회귀모형은 무수히 많다. 따라서 적합(fitting)된 회귀식들 중에서 결정계수가 크고, Mean Squared Error(MSE)가 작은 최적의 회귀모형을 찾는 작업이 필요한데, 이를 위해 모든 가능한 회귀, 전진선택법, 후진제거법, 단계별선택법 등이 선택 가능하다. 이러한 방법들을 통해 데이터를 변환한 후에 통계적으로 유의한 변수들을 남기고 모형을 구성할 수도 있지만, 사용되는 계층화 샘플링 다중 회귀방법에서는 작은 모집단에서의 최적 모형이 전체 집단을 가장 잘 설명하는 모형이라는 보장을 할 수 없게 된다. 따라서, 이번 연구에서는 효과적인 변수 선택과 예측력이 좋은 모형을 만들기 위하여 커널(kernel) 함수의 개념을 도입해 입력 데이터를 변환하여 모형을 구성하는 방식을 채택하였다.

입력 데이터 행렬 X , Y 데이터들의 다양한 분포를 파악하기 위해서, 각 변수의 히스토그램(histogram)을 살펴보았다. 다음의 <그림 8>은 독립변수 x_{20} , x_{100} , x_{210} 와 종속변수인 몰입도의 히스토그램을 나타내고 있다. 이 그림에서 볼 수 있듯이, 수집된 독립변수와 종속변수는 대체로 정규분포에서 벗어나 있어, 적절한 변환이 필요한 상황이었다.




<그림 8> 일부 독립변수와 종속변수의 히스토그램

본 연구의 감정 예측모형의 경우 독립변수 X 의 변수의 개수가 272개로 아주 많고, 변수들이 행동의 형태에 따라 선형으로만 의미가 있는 것이 아니라 다양한 형태로 의미를 가질 수 있는 특징이 있다. 이러한 점들을 종합적으로 고려해, 커널 함수 개념에 기반을 둔 데이터 변환으로 \sqrt{X} , $\log(|X|+\tau)$ 의 2가지를 적용하였다. 여기서 τ 는 \log 함수를 안정화시키기 위해 도입하는 아주 작은 상수 값이며, $1e-5$ 를 사용하였다.

종속변수인 Y 의 변환을 위해서는 전통적으로 많이 사용되었던 Box-Cox 변환 방법(또는 Power 변환)을 사용하고자 하였다. 다만, 이번 연구에서 Y 의 분산과 평균의 명확한 관계를 찾기 어렵고, 변환 λ 값으로 Y 의 물리적 의미를 설명하기 어렵다는 단점을 고려하여, 최종적으로 다음의 변환 규칙을 사용하였다.

$$Y^* = -\log\left(\frac{2+\tau}{Y+1+\tau/2} - 1\right)$$

이 때 τ 는 독립변수 때와 마찬가지로 $1e-5$ 를 사용하였다. 위의 변환 방법을 적용한 후의 Y 의 분포는 다음의 <그림 9>와 같이 바뀌게 된다.




<그림 9> 변환된 종속변수의 히스토그램

앞서 설명한 변환의 방법으로 X , Y 를 재구성한 뒤, 다중회귀분석 방법을 적용하여 몰입도

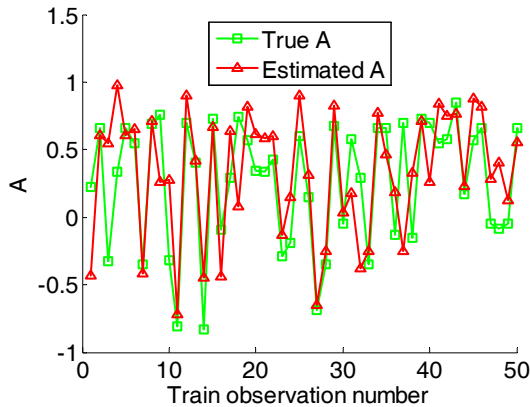
예측 모형을 구축하였다. 이 때, 또 다른 계층화 추출을 통해 확보한 6,025건의 표본으로 $X^{(test)}$, $Y^{(test)}$ 를 구성하여 모형의 예측정확도를 R^2 을 이용하여 계산해 보았다. 다중회귀분석에 사용된 최종 독립변수로는 원래값 X 와 커널 변환된 \sqrt{X} , $\log(|X|+\tau)$ 가 모두 포함된 $X^* = [X \sqrt{X} \log(|X|+\tau)]$ 를 사용하기로 하였기 때문에, X 의 변수가 267개 이므로 X^* 의 변수 개수는 801개가 되고, 회귀모형의 절편 상수까지 고려하면 총 802개의 변수를 고려하는 셈이 된다. 이상 설명한 자료의 변환 및 다중회귀모형의 모든 학습과정은 이기천 외[2014]의 연구에서 사용된 MATLAB 소프트웨어를 통해 구현되었다.

실험 결과, 계층화 샘플링을 $B = 10,000$ 회 수행하여 몰입도를 예측하는 다중회귀모형들의 R^2 값은 0.4227 ± 0.0184 이 되는 것으로 나타났다. 최종적으로 산출된 총 802개의 β 값을 그래프로 나타낸 결과가 <그림 10>에 제시되어 있다.



<그림 10> 독립변수 계수 및 절편값 분포

최종 산출된 몰입도 예측 모형의 성능을 보다 정밀하게 검증하기 위해, 임의의 50건 표본을 다시 추출한 뒤, 이 표본들에 대한 실제 몰입도 값과 예측 모형의 추정값을 비교해 보았다(<그림 11>참고). 그 결과 예측 모형의 추정값이 실제값과 거의 같은 패턴으로 산출됨을 확인할 수 있었다.



〈그림 11〉 실제 몰입도 값과 예측 모형의 추정치 비교

4.2 반응형 추천모듈의 구현

몰입도 예측 모형에 기반한 감정 예측모듈이 1차 추천 콘텐츠(C_0)를 시청하는 사용자의 반응을 토대로 -1에서 1사이의 값을 갖는 전반적인 몰입도 예측치 $A(C_0)$ 를 산출하면, 반응형 추천 모듈에서는 $A(C_0)$ 를 기반으로 아래 규칙에 따라 다음에 추천할 2차 추천 콘텐츠(C_1)를 결정하게 된다.

```

If  $A(C_0) < 0$  Then
     $C_1 = opposite(C_0)$ 
Else
     $C_1 = similar(C_0)$ 
End If
    
```

위 규칙에서 $opposite(C)$ 는 콘텐츠 C와 유사도가 가장 작은 콘텐츠를 반환하는 함수이고, $similar(C)$ 는 C와 가장 유사도가 높은 콘텐츠를 반환하는 함수이다. 이 때 유사도는 내용기반 추천 알고리즘의 원리를 차용하여, 콘텐츠를 구성하는 속성들 간의 거리(차이)를 기준으로 측정하고자 하였다.

본 연구의 경우, 디지털 멀티미디어 콘텐츠, 그

중에서도 ‘영화 예고편’을 대상으로 연구를 수행하였기 때문에, 콘텐츠를 구성하는 속성으로 개봉일, 장르, 감독, 각본, 출연배우를 고려하였다. 이러한 속성변수들로부터 유사도(콘텐츠간 거리)를 산출하는 방법은 Debnath et al.[2008]의 연구를 참조하여, 다음의 <표 1>과 같이 측정하였다.

〈표 1〉 영화 특성별 유사도 계산 방법

속성변수	유사도 계산 방법
개봉일	날짜로 환산하여, 절대값 차이를 계산한 뒤, Max 값에서 차감(해당 값이 0~1의 값을 갖도록 사후에 Min-Max 정규화를 적용)
장르	$\frac{G_1 \cap G_2}{G_{max}}$
감독	$D_1 = D_2? : 1 \text{ or } 0$
각본	$W_1 = W_2? : 1 \text{ or } 0$
배우	$\frac{C_1 \cap C_2}{C_{max}}$

각 속성변수별 유사도가 산출되면, 전체 유사도는 이들을 가중합하여 산출하였다. 이 때 가중합 비중은 기존 연구[Debnath et al., 2008] 결과와 전문가 의견을 종합적으로 참고해 **개봉일 : 장르 : 감독 : 각본 : 배우 = 1 : 4 : 2 : 1 : 2**로 하였고, 원활한 계산을 위해 0~1사이의 값을 갖는 각 속성별 유사도에 100을 곱해, 총 100점 만점의 유사도가 산출되도록 하였다.

4.3 유용성 검증을 위한 실험설계 및 결과

이상 제시한 새로운 MCCRS의 유용성을 검증하기 위해, 본 연구에서는 총 30명의 학부과정 학생들(남성, 여성 각각 15명씩)을 피실험자로 하여 실험을 진행하였다. 이들 피실험자들은 모두 20대 초중반(여성 평균 연령 20.9세, 남성 평균 연령 23.2세)이었기 때문에, 먼저 첫 추천 동영상으로 20대 남성 혹은 20대 여성이 가장 선호하는 것으로 조사된 영화의 예고편을 보여

〈표 2〉 실험에 사용된 영화 예고편

피실험자 인구통계특성	1차 추천 영상 (인구통계정보 기반 추천)		2차 추천 영상 (사용자 반응 기반 추천)		
	영화명	선호도 (100점)	구 분	영화명	유사도 (100점)
20대 남성	아저씨	91.6	유사 속성	의형제	28.13
			반대 속성	악마를 보았다	0.06
20대 여성	도가니	94.9	유사 속성	내 갱패같은 애인	27.29
			반대 속성	의뢰인	0.06

주었다. 그런 다음, 해당 영상을 시청할 때 보여준 반응을 키넥트 센서로 수집해 몰입도를 측정하고, 이 몰입도 측정결과를 바탕으로 처음 보여준 예고편과 가장 유사한, 혹은 가장 성격이 다른 예고편을 새롭게 추천하여 보여주었다. 이 과정에서 피실험자들에게 처음 추천된 영화 예고편을 시청한 뒤, 1차로 해당 예고편에 대한 만족도와 몰입도를 7점 리커트(Likert) 척도로 응답하게끔 하였으며, 이어 반응에 따라 추천된 새로운 영화 예고편을 시청하게 한 뒤 다시 한 번 만족도와 몰입도를 답변하게끔 하였다. 이를 통해 인구통계정보에 기반한 영화예고편 추천결과와 사용자 반응에 기반한 추천결과 사이에 만족도 및 몰입도 차원에서 어떤 차이가 있는지, 그리고 그 차이가 통계적으로 유의한 지 살펴보고자 하였다. 이처럼 사용자의 설문을 통해 추천시스템의 유용성을 검증하는 방법은 기존 연구[김경재, 안현철, 2005; 안현철 외, 2006 등]에서도 종종 사용되어 온 방식이다.

본 실험을 위한 영화 예고편 DB는 2009~2012년 사이에 개봉된 한국영화 중에서 유튜브³⁾에 예고편 영상이 공개되어 있는 100편의 영화를 대상으로 본 연구팀에서 자체 구축하였다. 이 DB에는 개봉일(YYMMDD), 장르(최대 3개까지), 감독, 각본, 배우(최대 5명까지)에 관한 영화의 특성 변수가 포함되어 있다. DB 구축을 위한 자료

의 원천으로는 네이버(Naver) 영화⁴⁾를 사용하였다. 네이버 영화 사이트에서는 남성관객의 평점과 여성관객의 평점, 그리고 10~40대별 관객평점이 10점 만점으로 제공되고 있어, 이 정보를 DB에 추가하여 성별 및 연령대에 따른 선호도도 산출할 수 있었다. 본 연구에서는 {성별 평점×50 + 연령대 평점×50}의 산식을 통해 100점 만점의 선호도를 산출해 사용하였다.

DB에 수록된 100편의 영화 예고편 중에서 실험에 최종적으로 사용된 영상 6편이 다음의 <표 2>에 제시되어 있다. 전술한대로 모든 피실험자가 20대 남성 혹은 여성이었기 때문에, 1차로 추천될 영상은 총 2편으로 고정된다. 이어 각 영상별 가장 유사한, 그리고 가장 유사하지 않은 영상이 각각 2편씩, 4편이 추가되므로 총 6편의 영상이 이번 실험에 사용되었다.

다음의 <표 3>은 30명의 피실험자가 응답한 1차~2차 상영 영상에 대한 만족도 및 몰입도 평균을 나타내고 있다. 이 표를 통해 알 수 있듯이, 평균적으로 1차 추천 영상과 비교해 2차 추천 영상에서 더 높은 만족도와 몰입도가 사용자에게 제공되었음을 확인할 수 있다. 성별에 따라 구분해 볼 경우에도, 남성과 여성 모두 2차 추천 영상에 대한 만족도와 몰입도가 1차 추천 영상과 비교해 평균적으로 항상 더 높게 응답되었음을 확인할 수 있다.

3) <http://www.youtube.com/>.4) <http://movie.naver.com/>.

〈표 3〉 피실험자들의 만족도 및 몰입도 응답 결과

구 분	1차 추천 영상 (인구통계정보 기반 추천)		2차 추천 영상 (사용자 반응 기반 추천)	
	만족도	몰입도	만족도	몰입도
20대 남성	3.93	4.40	4.60	5.20
20대 여성	4.33	4.47	4.53	5.20
전체	4.13	4.43	4.57	5.20

이러한 만족도와 몰입도의 차이가 과연 통계적으로 유의한 것인지 확인하기 위해, 대응표본 t-검정을 수행해 보았다. 수행 결과, 만족도는 95%($t = -2.443$, p -value = 0.021), 몰입도는 99%($t = -3.802$, p -value = 0.001) 신뢰수준 하에서 그 차이가 통계적으로 유의함을 알 수 있었다.

5. 결 언

본 연구는 사용자의 내적 상황정보에 해당되는 사용자의 감정을 예측하여, 그 결과를 바탕으로 사용자의 니즈 변화에 바로 대응할 수 있는 새로운 개념의 상황인지 추천시스템을 제안하였다. 제안한 시스템의 적용 가능성을 실제적으로 검증하기 위해, 본 연구에서는 MCCRS라 불리는 디지털 콘텐츠 상황인지 추천시스템을 실제로 개발 및 적용하였으며, 그 결과 사용자들이 상황인지 기술에 의해 추천된 결과에 대해 더 몰입하고 더 만족해 한다는 사실을 확인할 수 있었다.

본 연구의 의의를 학술적 그리고 실무적 관점에서 간략히 정리해 보면 다음과 같다. 첫째, 이론적 배경에서 소개한 것과 같이 지금까지 수행되어 온 상황인지 추천시스템 연구들의 경우, 주로 계량적 접근이 용이한 사용자의 외부 상황(주로 위치, 시간 등)에 대해서만 고려했을 뿐, 사용자의 내부 상황에 대해서는 거의 다루지 못했다. 특히 상황인지 서비스에 활용하기 위해 심리학의 기본 이론들을 기반으로 인간의 감정

을 모델링을 시도한 연구는 Yoo et al.[2011]나 Hsieh[2011] 등의 논문을 제외하고 거의 찾아보기 힘들다. 하지만, Yoo et al.[2011] 역시 연구의 초점이 감정의 모델링에 국한되어 있어, 이를 개인화 서비스나 추천시스템과 연계하고, 그것이 사용자가 체감하는 서비스 향상에 실제로 기여하는지까지는 실증적으로 분석하지 못했다는 한계가 있다. Hsieh[2011]의 경우, 사용자의 감정과 추천시스템을 연계하는 부분이 반영되어 있지만, 감정의 모델링이 단순하고, 그 예측이 사용자의 설문에 의존하게끔 설계되어 있다는 점에서 한계가 있다. 이에 비해 본 연구는 사용자의 얼굴표정 및 움직임과 같은 직접적인 반응을 감지하여, 심리학 분야에서 전통적으로 적용되어 온 V-A 모형 기반의 감정 상태를 예측하고, 다시 그 예측된 감정을 토대로 사용자에게 대한 2차 추천이 이루어지는 일련의 과정을 모두 연구모형에 포함하고 있으며, 이것들을 모두 실제 데이터에 기반해 구현하고 그 효과를 실증 분석한다는 측면에서 최근 발표되고 있는 논문들과 비교할 때 상당히 진일보된 연구 주제와 범위를 다루고 있다고 할 수 있다.

둘째, 본 연구는 Microsoft에서 개발한 키넥트 센서를 적용함으로써, 감정 예측을 위한 정보원으로 얼굴 표정은 물론 움직임 정보까지 활용한다는 점에서 기존 연구와 차별화된다. 지금까지 사용자의 반응을 토대로 감정을 예측하는 기존 연구들은 대체로 얼굴 표정의 변화를 주 정보원으로 활용해 왔다[고광은, 심귀보, 2009;

고현주 외, 2003; 박재언 외, 2010; Wong and Cho, 2009]. 하지만 본 연구에서는 Nicolaou et al.[2011]의 연구 등을 참고하여, 얼굴 표정 외에 어깨 및 목 움직임과 같은 정보까지 추가로 활용해 사용자의 감정을 예측하도록 설계되어 있어, 보다 정확한 감정 예측이 가능할 수 있다. 특히 Nicolaou et al.[2011]의 경우, 카메라를 센서로 활용하였기 때문에 근접도(proximity)와 같은 정보는 수집하지 못하였으나, 본 연구의 경우, 주요 신체의 위치를 3차원 좌표값으로 측정해 주는 키넥트 센서를 사용하기 때문에 근접도를 포함해 보다 정밀한 사용자의 움직임을 측정할 수 있었다.

셋째, 본 연구는 실무적 활용가치가 매우 높은 주제를 다루고 있다는 점에서 큰 의의를 갖고 있다. 사용자의 상태를 실시간으로 감지하여, 적절한 광고를 추천해 주는 기술은 과거 ‘마이너리티 리포트(Minority Report, 2002년 작)’와 같은 SF 영화에서도 소개될 정도로, 미래에 보편화될 것으로 예상되는 첨단 기술 중 하나이다. 때문에, 인간의 얼굴표정과 같은 반응으로부터 감정 상태를 예측하는 기술은 MIT Media Lab.과 같이 미래 기술을 연구하는 선도적인 연구기관에서 지금까지 활발하게 연구되어 왔다. 특히 MIT Media Lab.의 경우, 이 기술을 지속적으로 발전시켜 최근 Affectiva라는 벤처기업을 분사(spinner)시켰는데, 이 회사에서 출시한 Affectiva라는 제품의 경우, 광고 효과에 대한 검증이나 사이버 교육 매체에 대한 실시간 몰입도 측정 등 다양한 분야에서 인기에 적용되고 있다. 이렇듯 감정 예측을 위한 지능형 정보기술 개발에 대한 해외 기관 및 기업들의 움직임이 활발한데 비해, 이 분야에 대한 국내 연구는 학술대회에서 몇 차례 초기 단계의 연구들이 발표되고 있는 것을 제외하고는 많이 찾아보기 힘들다. 특히 경영정보시스템의 관점에서 이 분야를 접근하는 연구들은 더 찾아보기 힘들다는 점에서, 본 연구는 국가

경쟁력을 확보하는 차원에서도 상당히 유의미한 주제를 다루고 있는 연구라고 할 수 있다.

이렇듯 본 연구의 학술적, 실무적 의의를 다양한 각도에서 찾아볼 수 있겠으나, 다음과 같은 몇 가지 실험설계 상의 문제점들로 인해 그 성과는 제한적으로 수용되어야 할 것으로 보인다.

우선 첫째로 본 실험설계에는 주시험효과(attention bias)의 가능성이 존재한다. 검증 실험과정 중 본 연구에서는 1차로 추천 콘텐츠를 보여준 뒤 만족도와 몰입도를 측정하고, 이후 새롭게 추천된 콘텐츠를 보여준 뒤 다시 만족도와 몰입도를 측정했는데, 이 때 나중에 측정된 설문은 앞의 자극영상에 불가피하게 영향을 받게 된다. 때문에 추후 연구에서는 이러한 주시험효과(attention bias)의 위험을 회피할 수 있는 실험설계 상의 보완이 요구된다.

둘째, 추천 알고리즘에 사용된 특성 변수들은 영화에 대한 변수들이며, 실제 자극은 예고편을 활용함으로써 인해 발생할 수 있는 문제를 지적할 수 있다. 이렇게 되면, 예고편이 다루고 있는 영화의 특성에 따라 만족도와 몰입도가 결정되는 것이 아니라, 영화 예고편 자체의 특성(예고편의 품질 또는 예고편의 형식 등)에 따라 만족도와 몰입도가 결정될 위험이 있다. 때문에 향후에 수행될 연구에서는 추천대상이 되는 콘텐츠 자체의 특성을 보다 정밀하게 반영한 특성변수를 사용하여 실험을 수행할 필요가 있다.

아울러, 설문조사의 범위와 영화 예고편 DB의 규모가 다소 협소했다는 점 역시 본 검증실험의 한계점으로 지적될 수 있다. 설문대상이 여권상 20대의 학부학생에 제한되고 그 수도 30건으로 매우 작았다는 점과 영화 예고편 DB의 규모가 100편에 한정된 점 역시 추후 진행될 연구에서 극복되어야 할 한계라 할 수 있다.

이러한 한계들은 참조할만한 전례가 흔치 않았고, 본 연구에서 다른 주제가 도전적인 성격이 강했기 때문에 불가피했던 한계들이라 판단

된다. 때문에 향후 제안 시스템에 대한 보다 견고한 검증이 학술적, 실무적으로 이루어질 필요가 있다 하겠다.

참 고 문 헌

- [1] 고광은, 심귀보, “FACS와 AAM을 이용한 Bayesian Network 기반 얼굴 표정 인식 시스템 개발”, *한국지능시스템학회 논문지*, 제19권 제4호, 2009, pp. 562-567.
- [2] 고현주, 이대중, 전명근, “얼굴표정과 음성을 이용한 감정인식”, *정보과학회논문지 : 소프트웨어 및 응용*, 제31권 제6호, 2004, pp. 799-807.
- [3] 김경재, 안현철, “개선된 데이터마이닝 기술에 의한 웹 기반 지능형 추천시스템 구축”, *Journal of Information Technology Applications and Management*, 제12권 제3호, 2005, pp. 42-56.
- [4] 김경재, 안현철, “개인화된 추천시스템을 위한 사용자-상품 매트릭스 축약기법”, *Journal of Information Technology Applications and Management*, 제16권 제1호, 2009, pp. 97-113.
- [5] 김성진, 정민규, 유은정, 김재경, 안현철, “Support Vector Regression을 활용한 지능형 감정판단모형의 개선”, *지능정보연구*, 제18권 제3호, 2012, pp. 185-202.
- [6] 김재경, 서지혜, 안도현, 조운호, “A personalized recommendation methodology based on collaborative filtering”, *지능정보연구*, 제8권 제2호, 2002, pp. 139-157.
- [7] 김재경, 안도현, 조운호, “Development of a personalized recommendation procedure based on data mining techniques for internet shopping malls”, *지능정보연구*, 제9권 제3호, 2003, pp. 177-191.
- [8] 김재경, 안도현, 조운호, “개인별 상품추천시스템, WebCF-PT : 웹마이닝과 상품계층도를 이용한 협업필터링”, *경영정보학연구*, 제15권 제1호, 2005, pp. 63-79.
- [9] 김종우, 배세진, 이홍주, “협업 필터링 기반 개인화 추천에서의 평가자료의 희소 정도의 영향”, *경영정보학연구*, 제14권 제2호, 2004, pp. 131-149.
- [10] 박재언, 황민철, 김용우, 김지혜, 문성철, 조봉화, “얼굴 인식에 의한 각성도 측정에 관한 연구”, *대한인간공학회 2010 춘계학술대회 한일 공동학술대회논문집*, 2010, pp. 219-223.
- [11] 안현철, 한인구, 김경재, “연관규칙기법과 분류모형을 결합한 상품 추천 시스템 : G 인터넷 쇼핑몰의 사례”, *Information Systems Review*, 제8권 제1호, 2006, pp. 181-201.
- [12] 유은정, 안현철, 김재경, “고객 맞춤형 서비스를 위한 관객 행동 기반 감정 예측모형”, *지능정보연구*, 제19권 제2호, 2013, pp. 73-85.
- [13] 이기천, 최소윤, 김재경, 안현철, “Multimodal Emotional State Estimation Model for Implementation of Intelligent Exhibition Services”, *지능정보연구*, 제20권 제1호, 2014, pp. 1-14.
- [14] 정민규, 김재경, “개인화 전시 서비스 구현을 위한 지능형 관객 감정 판단 모형”, *지능정보연구*, 제18권 제1호, 2012, pp. 39-57.
- [15] 조운호, 박수경, 안도현, 김재경, “재구성된 제품 계층도를 이용한 협업 추천 방법론 및 그 평가”, *한국경영과학회지*, 제29권 제2호, 2004, pp. 59-75.
- [16] 최아영, 우운택, “감정 분석을 위한 생체 신호 특징 추출”, *2005 한국HCI학회 학술대회 (HCI 2005) 논문집*, 2005, pp. 624-629.

- [17] Adomavicius, G., Sankaranarayanan, R., Sen, S., and Tuzhilin, A., "Incorporating contextual information in recommender system using a multi-dimensional approach", *ACM Transactions on Information Systems*, Vol. 23, No. 1, 2005, pp. 103-145.
- [18] Anand, S. S. and Mobasher, B., "Intelligent Techniques for Web Personalization", *Lecture Notes in Artificial Intelligence*, Vol. 3169, 2005, pp. 1-36.
- [19] Brainerd, C. J., Holliday, R. E., Reyna, V. F., Yang, Y., and Toglia, M. P., "Developmental reversals in false memory : Effects of emotional valence and arousal", *Journal of Experimental Child Psychology*, Vol. 107, 2010, pp. 137-154.
- [20] Burke, R. D., Hammond, K. J., and Young, B. C., "Knowledge-based navigation of complex information spaces", Proceedings of the 13th National Conference on Artificial Intelligence, 1996, pp. 462-468.
- [21] Chen, A., "Context-aware Collaborative Filtering System", *Lecture Notes in Computer Science*, Vol. 3479, 2005, pp. 244-253.
- [22] Dao, T. H., Jeong, S. R., and Ahn, H., "A novel recommendation model of location-based advertising : Context-Aware Collaborative Filtering using GA approach", *Expert Systems with Applications*, Vol. 39, No. 3, 2012, pp. 3731-3739.
- [23] Debnath, S., Ganguly, N., and Mitra, P., "Feature weighting in content based recommendation system using social network analysis", Proceedings of the 17th International Conference on World Wide Web(WWW 2008), 2008, pp. 1041-1042.
- [24] Dey, A., Abowd, D., and Salber, D., "Conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications", *HCI Journal*, Vol. 16, No. 2, 2001, pp. 97-166.
- [25] Ekman, P., "Universals and Cultural Differences in Facial Expressions of Emotion", In J. Cole (Ed.), *Nebraska Symposium on Motivation*, Vol. 19, 1972, pp. 207-282.
- [26] Funakoshi, K. and Ohguro, T., "A Content-Based Collaborative Recommender System with Detailed Use of Evaluations", Proceedings of the 4th International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies (KES 2000), 2000, pp. 253-256.
- [27] Haubl, G. and Trifts, V., "Consumer Decision Making in Online Shopping Environments : The Effects of Interactive Decision Aids", *Management Science*, Vol. 19, No. 1, 2000, pp. 4-21.
- [28] Hsieh, K.-L., "Employing a recommendation expert system based on mental accounting and artificial neural networks into mining business intelligence for study abroad's P/S recommendations", *Expert Systems with Applications*, Vol. 38, No. 12, 2011, pp. 14376-14381.
- [29] Kaminskas, M. and Ricci, F., "Contextual music information retrieval and recommendation : State of the art and challenges", *Computer Science Review*, Vol. 6, No. 2-3, 2012, pp. 89-119.
- [30] Kwon, O. B., "I know what you need to buy' : context-aware multimedia-based recommendation system", *Expert Systems*

- with Applications*, Vol. 25, No. 3, 2003, pp. 387-400.
- [31] Lemire, D., Boley, H., McGrath, S., and Ball, M., "Collaborative filtering and inference rules for context-aware learning object recommendation", *Interactive Technology and Smart Education*, Vol. 2, No. 3, 2005, pp. 179-188.
- [32] Miller, B. N., Albert, I., Lam, S. K., Konstan, J. A., and Riedl, J., "Movielens unplugged : Experiences with an occasionally connected recommender system", Proceedings of ACM 2003 Conference on Intelligent User Interfaces(IUI'03), 2003, pp. 263-266.
- [33] Nicolaou, M. A., Gunes, H., and Pantic, M., "Continuous Prediction of Spontaneous Affect from Multiple Cues and Modalities in Valence-Arousal Space", *IEEE Transactions on Affective Computing*, Vol. 2, No. 2, 2011, pp. 92-105.
- [34] Pine, II, B. J., Mass Customization, Harvard Business School(HBS) Press, Boston, MA, 1993.
- [35] Russell, J. A., "Pancultural aspects of the human conceptual organization of emotions", *Journal of Personality and Social Psychology*, Vol. 45, No. 6, 1983, pp. 1281-1288.
- [36] Schafer, J., Konstan, J., and Riedl, J., "E-Commerce Recommendation Applications", *Journal of Data Mining and Knowledge Discovery*, Vol. 5, No. 1-2, 2001, pp. 115-153.
- [37] Schiaffino, S. and Amandi, A., "Building an expert travel agent as a software agent", *Expert Systems with Applications*, Vol. 36, No. 2, Pt. 1, 2009, pp. 1291-1299.
- [38] Si, H., Kawahara, Y., Kurasawa, H., Morikawa, H., and Aoyama, T., "A Context-aware Collaborative Filtering Algorithm for Real World Oriented Content Delivery Service", Proceedings of the 7th International Conference on Ubiquitous Computing(Ubicomp2005), 2005, pp. 65-69.
- [39] Winoto, P. and Tang, T. Y., "The role of user mood in movie recommendations", *Expert Systems with Applications*, Vol. 37, No. 8, 2010, pp. 6086-6092.
- [40] Wong, J.-J. and Cho, S.-Y., "A local experts organization model with application to face emotion recognition", *Expert Systems with Applications*, Vol. 36, No. 1, 2009, pp. 804-819.
- [41] Yang, W.-S., Cheng, H.-C., and Dia, J.-B., "A location-aware recommender system for mobile shopping environments", *Expert Systems with Applications*, Vol. 34, No. 1, 2008, pp. 437-445.
- [42] Yoo, H., Kim, M.-Y., and Kwon, O., "Emotional index measurement method for context-aware service", *Expert Systems with Applications*, Vol. 38, No. 1, 2011, pp. 785-793.

■ 저자소개



안 현 철

현재 국민대학교 경영대학 경영정보학부 부교수로 재직 중이다. KAIST에서 산업경영학사를 취득하고, KAIST 테크노경영대학원에서 경영정보시스템을 전공하여 공학석사와 박사를 취득하였다. 주요 관심분야는 금융 및 고객관계관리 분야의 인공지능 응용, 정보시스템 수용과 관련한 행동 모형 등이다. *Annals of OR*, *Applied Intelligence*, *Applied Soft Computing*, *Expert Systems with Applications*, *Information and Management*, *International Journal of Electronic Commerce* 등의 국제학술지와 *Asia Pacific Journal of Information Systems*, *Journal of Information Technology Applications and Management*, *지능정보연구* 등의 국내학술지에 연구논문을 발표한 바 있다.